

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky

DIPLOMOVÁ PRÁCE

2015

Aleš Vybíral

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Biometrická identifikace osob pro nabíjecí stojany

Biometric Identification for Charging Stations

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání diplomové práce

Student: **Bc. Aleš Vybíral**
Studijní program: N2649 Elektrotechnika
Studijní obor: 3901T009 Biomedicínské inženýrství
Téma: **Biometrická identifikace pro nabíjecí stojany**
Biometric Identification for Charging Stations

Zásady pro vypracování:

Diplomová práce se zabývá analýzou metod biometrické identifikace pro přihlášení obsluhy nabíjecích stojanů pro elektromobily. Cílem práce je navrhnout a realizovat software, který by byl schopen v reálném čase přihlásit uživatele do informačního systému na základě snímku duhovky.

Celá práce je charakterizována těmito body:

1. Rešerše metod biometrické identifikace.
2. Rešerše metod snímání duhovky.
3. Nalezení vhodného algoritmu pro vhodnou implementaci.
4. Návrh a implementace algoritmu.
5. Experimentální ověření, případně srovnání s komerčními produkty.
6. Závěr a zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] BURGE, Mark J. and Kevin BOWYER, ed. *Handbook of Iris Recognition (Advances in Computer Vision and Pattern Recognition)*. London: Springer-Verlag, 2013. ISBN 978-1-4471-4401-4.
- [2] RAK, Roman. *Biometrie a identita člověka ve forenzních a komerčních aplikacích*. 1. vyd. Praha: Grada, 2008, 631 s., 32 s. barev. obr. příl. ISBN 978-80-247-2365-5.
- [3] PARKER, J. R. *Algorithms for Image Processing and Computer Vision*. Indianapolis (USA): Wiley Publishing Inc., 2010. ISBN 978-0-470-64385-3.
- [4] GONZALEZ, Rafael C., Richard E. WOODS and Steven L. EDDINS. *Digital Image Processing Using MATLAB, 2nd ed.* 2nd ed. Natick: Gatesmark Publishing, 2009, xviii, 826 s. ISBN 978-0-9820854-0-0.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Zdeněk Slanina, Ph.D.**

Datum zadání: 01.09.2013

Datum odevzdání: 07.05.2015



doc. Ing. Jiří Kozíorek, Ph.D.
vedoucí katedry



prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prohlášení

„Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením Ing. Zdeňka Slaniny, Ph.D. Veškerou literaturu a další zdroje, z nichž jsem při zpracování čerpal, v práci řádně cituji a uvádím v seznamu použité literatury.“

V Ostravě dne 5. 5. 2015


.....
Bc. Aleš Vybíral

Poděkování

Tímto bych rád poděkoval vedoucímu diplomové práce, Ing. Zdeňku Slaninovi, Ph.D za jeho trpělivost a spolupráci při tvorbě této práce a čas věnovaný našim konzultacím. Také bych chtěl rád poděkovat mým rodičům za podporu a možnost absolvovat vysokoškolské studium

ABSTRAKT

Biometrická identifikace je v posledních letech stále více se rozvíjející obor s rostoucím množstvím možných aplikací. Jedna z nejefektivnějších metod biometrické identifikace se provádí pomocí sejmutého snímku oční duhovky, jejíž textura slouží jako jedinečný znak dané osoby. Za zakladatele této metody bývá považován J. Daugman, podle něhož byla jedna z metod pojmenována. Diplomová práce v úvodních kapitolách popisuje obecně biometrickou identifikaci, jednotlivé biometrické metody a následně i biometrickou identifikaci pomocí oční duhovky. Následuje praktická část práce, ve které byl z předložených metod řešení navrhnout algoritmus pro zpracování snímků oční duhovky a implementován do systému MATLAB. Druhá polovina praktické části je věnována testování spolehlivosti vytvořeného systému a přehledně popsána tabulkami a odpovídajícími grafy. Poslední část práce pak shrnuje dosažené výsledky.

KLÍČOVÁ SLOVA

Biometrická identifikace, detekce duhovky, segmentace, normalizace, extrakce, Houghova transformace, korelace, FAR, FRR, MATLAB, CASIA

ABSTRACT

In recent years, biometric identification is far more growing field with a increasing number of possible applications. One of the most effective methods of biometric identification is performed by a captured image of the iris texture which is serves as a unique feature of a person. The founder of this method is considered J. Daugman, according to him it was named one of the methods. In introductory chapters, this thesis describes biometric identification in general, individual biometrics and subsequently biometric identification using iris. Followed by the practical part, which has been submitted solving methods designed algorithm for image processing iris and implemented in MATLAB. The second half is devoted to the practical part of reliability testing createdd system and clearly describes the respective tables and graphs. The last section summarizes the results.

KEY WORDS

Biometric identification, iris detection, segmentation, normalization, extraction, Hough transformation, correlation, FAR, FRR, MATLAB, CASIA

Seznam použitých zkratek

CCD	Charged-coupled device
EER	Equal Error Rate
FAR	False Accept Rate
FRR	False Reject Rate
GUI	Graphical User Interface
HW	Hardware
SW	Software

Obsah

1	ÚVOD.....	- 1 -
2	BIOMETRICKÁ IDENTIFIKACE.....	- 2 -
2.1	Rozpoznávání	- 2 -
2.2	Verifikace	- 2 -
2.3	Identifikace	- 2 -
2.4	Autentizace	- 2 -
3	METODY BIOMETRICKÉ IDENTIFIKACE	- 3 -
3.1	Daktyloskopie	- 3 -
3.2	Geometrie ruky	- 6 -
3.3	Krevní řečiště hřbetu ruky	- 6 -
3.4	Geometrie tváře	- 8 -
3.5	Duhovka oka.....	- 9 -
3.6	Sítnice oka	- 10 -
3.7	Hlas a řeč	- 10 -
3.8	Dynamika podpisu	- 11 -
3.9	Chůze	- 12 -
3.10	DNA.....	- 12 -
4	ANALÝZA A SNÍMÁNÍ OČNÍ DUHOVKY	- 14 -
4.1	Anatomie oka a oční duhovky	- 14 -
4.2	Základní metody pro snímání oční duhovky	- 15 -
4.3	Zpracování snímků oční duhovky.....	- 16 -
4.4	Předzpracování snímků.....	- 17 -
4.5	Segmentace.....	- 19 -
4.6	Normalizace.....	- 22 -
4.7	Extrakce příznaků	- 23 -
4.8	Porovnávání příznaků	- 25 -
4.9	Metody analýzy oční duhovky.....	- 26 -
4.10	Hodnocení biometrických systémů.....	- 28 -
5	IMPLEMENTOVANÁ METODA DETEKCE A ZPRACOVÁNÍ SNÍMKŮ DUHOVKY	- 32 -
5.1	Akvizice snímků	- 32 -

5.2	Lokalizace duhovky v obraze	- 34 -
5.3	Normalizace duhovky	- 43 -
5.4	Extrakce příznaků	- 46 -
5.5	Ukládání dat do databáze	- 47 -
5.6	Porovnávání příznaků	- 48 -
5.7	Uživatelské rozhraní	- 49 -
6	ZHODNOCENÍ VÝSLEDKŮ	- 53 -
6.1	Průběh experimentu	- 53 -
6.2	Výsledky použité implementace	- 54 -
6.3	Sumarizace výsledků a doporučené rady pro další zpracování	- 59 -
7	ZÁVĚR	- 61 -
	Seznam použité literatury	- 62 -
	Seznam příloh	- 64 -

1 ÚVOD

Moderní technologie zasahují dnes již prakticky do všech sfér lidského bytí. Ať už nahlédneme do pracovního nebo osobního života kteréhokoliv člověka v rozvojových zemích, stále více se propojuje interaktivní svět s reálným. Je logickým vyústěním této situace, že každý se ve světě plném virtuálního terorismu bojí o svá citlivá data, ať už jde o soukromé profily na sociálních sítích, bankovních účtech, nebo citlivá firemní data chráněná značkou firmy. Proto se v posledních letech můžeme stále více setkat s modernějšími a sofistikovanějšími metodami ochrany dat známé v předešlých letech pouze z akčních filmů.

Prakticky celý svět je propojen internetovou sítí, s čímž souvisí i nekonečný přívál informací valící se ze všech stran na lidskou společnost. Každý lidský mozek má svou omezenou kapacitu a určitě každý z nás se již někdy setkal se situací, kdy stál před bankomatem, počítačem či si chtěl zapnout mobilní přístroj, ale nemohl si vzpomenout na svůj pin nebo přístupové heslo. Moderních technologií stále přibývá a tím i počty nových zařízení v domácnosti a zaměstnání, kde je na nás kladen důraz rok co rok vymýšlet nová a nová přístupová hesla. Z této situace vyvstává logická otázka: „Nebylo by možné tuto skutečnost vyřešit jiným, elegantnějším způsobem?“.

Možnou odpovědí na položenou otázku, se zabývá tato práce, která řeší nastalou situaci jednoduchým, avšak sofistikovaným způsobem – biometrickou identifikací. Obrovskou výhodou tohoto přístupu k dané věci je, že tak odpadá povinnost osoby pamatování si veškerých svých hesel a pinů. Jednoduše proto, že jednotlivé biometrické údaje má člověk doslova po ruce.

Závěrečná práce v úvodních kapitolách pojednává o možném způsobu biometrické identifikace osoby prostřednictvím oční duhovky, což je jedna z nejefektivnějších a nejspolehlivějších metod. Dále jsou předloženy jednotlivé metody zvoleného způsobu řešení, který je následně implementován do vytvořené aplikace s využitím uživatelského rozhraní v programu MATLAB. V posledních kapitolách práce je pak celý proces podrobně popsán a zhodnocen s možnými radami pro další rozšíření práce.

Jelikož se celý školní kampus modernizuje a spojuje s moderními informačními technologiemi má tato práce uplatnění s cílem zavedení této metody do praxe.

2 BIOMETRICKÁ IDENTIFIKACE

Biometrie je vědní obor, který se zabývá studií a zkoumáním živých organismů (především člověka) a měřením jeho biologických vlastností a jeho behaviorálních charakteristik. Pojem vznikl sloučením dvou řeckých slov – bios (život) a metron (měřit). Rozpoznávání osob pomocí biologických charakteristik je metoda využívaná historicky. Už v pravěku se lidé se rozpoznávali pomocí vzhledu tváře nebo jsou známy jejich otisky dlaní na stěně jeskyně jako jejich podpis. V dnešní době s rozvojem počítačových technologií se začíná biometrické rozpoznávání osob stávat automatizovaným.

V problematice biometrie je nutné správně rozumět základním pojmům, které mají původ v anglickém jazyce a jsou případy, kdy jsou do češtiny nesprávně překládány.

[1]

2.1 Rozpoznávání

Rozpoznávání neboli recognition je druhový termín, který nutně nemusí znamenat identifikaci ani verifikaci. Jedná se o rozpoznávání člověka použitím vhodné tělesné vlastnosti.

2.2 Verifikace

Ověření/verifikace – verification – označuje proces, při kterém se biometrický systém pokouší potvrdit totožnost jedince, srovnáváním sejmutého vzorku s již dříve zapsanou šablonou – princip one-to-one.

2.3 Identifikace

Identifikace neboli identification je proces, kdy se biometrický systém pokouší určit totožnost neznámého jedince. Biometrická informace je sejmuta a porovnávána se všemi uloženými šablonami – princip one-to-many.

2.4 Autentizace

Autentizace – authentication – je pojem, který lze sloučit s termínem rozpoznávání. Avšak na konci procesu v tomto případě získá uživatel určitý status (oprávněný/neoprávněný přístup).

[1] , [2]

3 METODY BIOMETRICKÉ IDENTIFIKACE

3.1 Daktyloskopie

Daktyloskopie je odnož biometrie identifikující osoby podle otisků prstů. Jde o jednu z nejstarších používaných metod. Poprvé se začala využívat v 19. století v kriminalistice a používá se dodnes. Metoda se natolik osvědčila, a proto hraje jednu z hlavních rolí při vývoji systémů pro automatickou identifikaci. Aplikace daktyloskopie je můžeme najít jak v profesionálních docházkových systémech, tak v mobilech, PDA, USB klíčenkách a v neposlední řadě slouží i jako náhrada přístupového hesla do operačních systémů v počítačích.

FRR	< 1,0 [%]
FAR	0,0001 – 0,00001 [%]
rychlost verifikace	0,2 – 1 [s]
míra spolehlivosti	vysoká

Tabulka 1 Parametry daktyloskopie

3.1.1 *Princip*

Daktyloskopie detekuje obrazce na polštářcích prstů skládaných z tzv. papilárních linií. Tyto linie vytváří určité unikátní vzory, které nazýváme markanty. Na obrázcích můžeme vidět několik příkladů těchto markantů. Pro elektronickou identifikaci však využíváme obvykle jen dva markanty, a to ukončení papilární linie a rozdvojení.

Princip spočívá v tom, že epidermální hřebeny a brázdy jedince mají různé charakteristiky pro různé otisky prstů. Konfigurační typy jsou proměnné pro jednotlivce, ale mění se uvnitř limitů, což dovoluje systematickou klasifikaci. Markanty a konfigurace papilárních linií jsou permanentní a neměnné. Tento princip tedy znamená, že nelze manuálně změnit otisk prstu, aniž by byla odstraněna zárodečná vrstva kůže.

3.1.2 *Klasifikace otisků prstů*

Systematickou klasifikaci umožňuje variace papilárních linií v centrální oblasti otisků prstů. Variace nejsou příliš velké, a tak není klasifikace příliš obtížná. Pro klasifikaci se volí tzv. vzorová oblast (pattern area), která je utvořena typovými liniemi. Typové linie obklopují centrální vzorovou oblast a jsou definovány jako dvě nejvnitřnější linie, které ohraničují centrální zkoumanou oblast otisků prstů.

V centrální oblasti se rozlišují dva základní body – delta a jádro. Delta je bod, kde se papilární linie rozbíhají nebo sbíhají, a jádro se vyznačuje tím, že se zde nachází střed dané kategorie otisků prstů.

Kategorie neboli typy otisků prstů jsou následující.

Smyčka – typ otisku prstu, kde jedna nebo více papilárních linií vstupují do otisku prstu, pokračují linií mezi jádrem a deltou a končí ve směru, kde začaly. Typ otisku „smyčka“ je takto klasifikován, nachází-li se v otisku nejméně jedna vhodně zakřivená papilární linie a obsahuje-li deltu.

Spirála – v tomto typu otisku prstu se nachází nejméně dvě delty se zakřivením na každé z nich. Navíc mohou být spirály děleny na plochou spirálu, spirálu se střední kapsou, dvojitou spirálu a náhodnou spirálu.

Oblouk – tento typ otisku prstu se dále dělí na typ plochý oblouk a klenutý oblouk. Zde papilární linie z jedné strany vstupují, z druhé strany vystupují a v některém místě uprostřed se mírně zvlňí.

Díky určitým nepřesnostem a unikátnosti otisků prstů je pro automatické systémy složité jednotlivé typy klasifikovat a následně rozeznávat. Proto se častěji využívá vzájemné postavení jednotlivých markantů.

3.1.3 Příklady algoritmů

Jednotlivé algoritmy se mohou značně odlišovat. Je to dáno tím, že vědci, vývojáři a jednotlivé firmy využívají rozdílné přístupy k řešení dané problematiky. Tyto přístupy však bývají velmi často obtížně vysvětlitelné, jelikož si výrobci své „know-how“ nechávají pro sebe a logicky je nezveřejňují.

Jsou zde uvedeny tedy pouze dva příklady možného řešení.

Rozeznávání podle vzájemné polohy markantů

Už z názvu plyne, že algoritmus je založen na srovnávání vzájemné polohy několika markantů. Jako první se sejmutý otisk převede do digitální formy, což se provádí už ve snímači. Dále se sejmutý již už digitální obraz předzpracuje filtrací, vyhlazením a skeletizací obrazu. Po těchto krocích jsou už v obraze snadno rozpoznatelné základní charakteristické rysy tvořeny markanty. Pro identifikaci postačí jen dva. Systém tedy obsahuje předem získaný vzor (např. vytvořením profilu pro daného člověka), se kterým srovnáváme získaný obrazec. V obou obrazech je nějaké množství bodů, které jsou tvořeny námi zvolenými markanty. Za předpokladu, že se podařilo nalézt ve vzoru i v získaném obraze alespoň dva identické body (stejný markant a stejné umístění), může systém přistoupit k dalšímu kroku. Zde se eliminují chyby způsobené elasticitou kůže, otočením otisku nebo změnou měřítka tak, že se otisk transformuje podle dvojice bodů na obraze a vzoru. V případě, že se podařilo nalézt touto transformací dostatek identických bodů, následuje poslední krok rozpoznání – korelace. Korelace se provádí jako odchylka obrazu od vzoru a určuje nám s jakou přesností je nalezený otisk shodný s otiskem v databázi.

Srovnávání podle míry vzájemné informace

Určení míry vzájemné informace u dvou jevů bývá používáno hlavně pro určení nezávislosti dvou jevů. Avšak u této metody používáme opačný postup. Cílem je určit, zda je vzájemná závislost natolik vysoká, aby se dalo jednoznačně tvrdit, že jde o totožné otisky prstů. Využívá se zde otisk prstů zachycen na neupraveném šedotónovém obraze. Také zde tkví největší problém v elasticitě kůže, což je řešeno afinními transformacemi (zachování paralelismu přímek – zachování papilárních linií) a proporcionality bodů, ležících na nich. Šedotónový obraz se definuje jako matice pixelů o různé úrovni jasu. V této metodě se pak v daných oblastech z relativních četností vypočítají entropie, pomocí kterých se srovnává vzájemná informace v obraze a vzoru. Jako kritérium odsouhlasení se udávají parametry transformace obrazu, díky které se dosáhlo maximální vzájemné informace.

3.1.4 Snímače otisků prstů

Z hlediska bezpečnosti řešení přístupového bodu je velice důležité zvolit správný typ snímače. Požadavky na snímače jsou různé, ať co do velikosti tak přesnosti a bezpečnosti. V reálném světě jsou k dispozici čtyři rozdílné typy snímačů.

Optoelektronické snímače

Princip snímání otisku prstu tohoto snímače spočívá v odlišném lomu světla na hranolu, na kterém je otisk prstu přiložen. Toto světlo pak zachycuje CCD snímač a digitalizuje ho. Nevýhodou tohoto typu snímače je, že na hranolu může zůstat zbytkový otisk prstu, který se při dalším snímání otisku může milně přimíchat ke snímanému otisku. Z čehož logicky plyne, že verifikace neproběhne v pořádku, dokonce v krajním případě může „smíchaný“ otisk prstu přiřadit jiné neoprávněné osobě. Tento problém se u kvalitnějších snímačů řeší nanesení silikonové fólie na hranol a vhodným nasvětlením.

Kapacitní snímače

Kapacitní snímače jsou oproti optoelektrickým snímačům velmi malé a ploché. Skládají se z pole aktivních mikroelektrod. Otisk prstu je získáván z aktivních pixelů. Nevýhodou tohoto přístupu je pouze dvoubarevný otisk prstu, což může při některých algoritmech rozpoznávání vadit.

Teplotní snímače

Teplotní snímače jsou vybaveny velice citlivým, teplotetekujícím čipem o malých rozměrech. Fungují na principu rozdílných teplot papilárních linií a prostoru mezi nimi. Otisk je získáván pomalým pohybem prstu přes tepločivý prvek. To je také největší nevýhodou teplotních snímačů. Při tomto způsobu je velice těžké získat kvalitní otisk prstu, pokud možno stejné části. Tyto snímače jsou tedy velice nespolehlivé a jejich využití je velice sporné.

Elektroluminiscenční snímače

Elektroluminiscenční snímače jsou složeny z několika vrstev. první základní vrstvou je sklo se zabudovanými fotodiodami. Nad touto vrstvou se nachází polymerová vrstva, která emituje světlo na základě tlaku. Tlak papilárních linií je větší než tlak volného prostoru mezi

nimi. Nad touto vrstvou je černá krycí vrstva a ochranná vrstva. Tyto snímače mají tu výhodu, že jsou extrémně malé a výkonné. Obraz z tohoto snímače dosahuje rozlišení kolem 500dpi. Další výhodou je, že obraz není zkreslován, když je prst suchý nebo vlhký. Nevýhodou pak může být náchylnost na znečištění a malé fyzická odolnost.

[3]

3.2 Geometrie ruky

Metoda identifikace podle geometrie ruky je založena na rozdílnosti rozměrů prstů, dlaně a velikosti nehtových lůžek.

FRR	< 0,1 [%]
FAR	0,1 [%]
rychlost verifikace	1 – 2 [s]
míra spolehlivosti	střední

Tabulka 2 Parametry geometrie ruky

3.2.1 *Princip a snímače*

Verifikace podle tvaru ruky je založena na třídimensionálním snímání ruky. Snímání probíhá CCD kamerou o malém rozlišení 32 000 pixelů. V průběhu kontroly dojde k asi devadesáti měřením. Z výsledného snímku se pak kontroluje délka, šířka a tloušťka jednotlivých prstů a dlaně. Tento snímek se pak redukuje na 9-ti nebo 20-ti bajtovou předlohu.

Algoritmy transformace snímku do předlohy jsou, obchodním tajemstvím firmy a proto se nevyskytují v této práci.

Verifikace touto metodou poskytuje několik výhod. Předloha je velmi paměťově nenáročná, a proto i do autonomního zařízení lze nahrát poměrně rozsáhlou databázi uživatelů. Další předností se může považovat fakt, že při správném nastavení je tato metoda velice bezpečná. Daná metoda také nevyžaduje žádné zaškolení uživatelů, protože je velice přirozená a intuitivní. Jako téměř vše, má tato metoda také své úskalí. V akademické obci se tvrdí, že se může jednat o nejsnáze oklamatelný systém. Identifikace osob touto metodou má však jednu hlavní nevýhodu a to, že geometrie ruky se s věkem může samozřejmě měnit. Tudíž tato metoda nevyužívá trvalou biometrickou charakteristiku, což je z hlediska uživatele krajně nekomfortní.

[3]

3.3 Krevní řečiště hřbetu ruky

Biometrická identifikace pomocí snímání struktury krevního řečiště hřbetu ruky je jedna z nejnovějších metod rozpoznávání jedince. První komerčně dostupné systémy jsou datovány k roku 2000. Tato technologie se vyznačuje velkou obtížností falšování. Síť cév je velice obtížné napodobit, jelikož je uvnitř ruky a není tedy viditelná pro napodobení. Některé principy navíc přímo vyžadují, aby řečištěm protékala teplá krev.

Technologie spočívá ve snímání hřbetu ruky speciální kamerou v infračerveném světle. Tímto způsobem se získá černobílý obraz stromové struktury žil, které tvoří zřetelný vzorec. Struktura krevního řečiště se navíc v dospělém věku příliš nemění, je velice výrazná a její jedinečnost i mezi jednovaječnými dvojčaty prokázaly některé vědecké studie. Výhodou je její bezkontaktní princip – uživatel se nemusí dotýkat povrchu snímače, což zvyšuje hygienu a pravděpodobnost správného přijetí uživatele.

FRR	0,01 [%]
FAR	0,00008 [%]
rychlost verifikace	1 – 2 [s]
míra spolehlivosti	vysoká

Tabulka 3 Parametry krevního řečiště hřbetu ruky

3.3.1 Snímání krevního řečiště

Snímání probíhá tak, že zdroj (pole LED diody) prosvítí ruku a na základě různé absorpce (odrazu) záření krevních cév a ostatních tkání se vytvoří obraz pomocí snímací CCD kamery. Obraz je dále digitalizován a zpracováván za cílem vyextrahování sítě cév. Ukládají se důležité vlastnosti jako body a úhly větvení cév a tloušťka cév.

Použitím zobrazení ve spektru blízkém infračervenému světlu (IR záření) se zvýrazní kontrast mezi cévním řečištěm hřbetu ruky a okolní kůží. Odkysličený hemoglobin v žilách pohlcuje světlo o vlnové délce přibližně 7.6×10^{-4} mm, což je hodnota blízká infračervenému světlu. Hloubka absorpce je IR záření živou tkání je přibližně 3 mm, tzn. že termální IR záření proniká do hřbetu ruky jen povrchově a v nasnímaném obrazu je pak nejvíce rozeznatelné právě celé cévní řečiště. Díky tomu jsou žíly na IR snímku vytaženy tmavou (černou) barvou.

Jakmile je sejmuto potřebný obraz hřbetu ruky, nastupuje další fáze rozpoznání žil ruky, která se může skládat ze 4 kroků. Jde o segmentaci obrazu (rozdělení na části), vyhlazení a redukce šumu, prahování a postprocessing.

3.3.2 Segmentace obrazu

Účelem tohoto primárního kroku je rozdělit nasnímaný obraz na část ruky, tj. požadované části, a pozadí obrazu. Vzniká tak bíle zobrazená část ruky a černé pozadí.

3.3.3 Vyhlazení a redukce šumu

Pro redukci šumu a vyhlazení obrazu se používá např. Gaussovské rozmazání (nezachová hrany) nebo nelineární rozptýlení (zachová hrany). Tento krok slouží k vyhlazení obrazu cévního řečiště a k potlačení případného vlivu tvaru hřbetu ruky.

3.3.4 Lokální prahování

Úkolem tohoto kroku je oddělit vzor žilní struktury od zbytku obrazu. Metody pro toho oddělení lze rozdělit do 4 skupin: segmentace prahováním, segmentace pomocí hran,

segmentace pomocí oblastí a segmentace porovnáváním. Výpočetně nenáročná a rychlá je první z uvedených metod. Používá se technika lokálního prahování, tj. výpočet průměrné hodnoty z okolních pixelů a použití této průměrné hodnoty jako hodnoty prahu.

3.3.5 *Postprocessing*

Posledním krokem je postprocessing, kde se již po finálních úpravách na obrázku vyskytuje pouze struktura žil hřbetu ruky ve stavu, který lze již označit jako šablonu. Následně se tato šablona pak využívá k vlastní verifikaci uživatele.

[3]

3.4 Geometrie tváře

Verifikace obličeje je dnes nejvíce zkoumanou metodou, neboť problematika identifikace osob dle tváře je velmi obsáhlá. Rozpoznávání je založeno na srovnávání obrazu sejmutého kamerou s obrazem, který je uložen v centrální databázi. K jednoznačné identifikaci slouží většinou tvar obličeje a poloha opticky významných míst na tváři, jako jsou oči, ústa nebo obočí. Obraz v počítači může být uložen jako matice jasových úrovní, častěji však diskriminován nějakou funkcí, která snižuje redundanci dat. Neukládá se tedy přesná poloha očí, nosu a rtů, ukládají se pouze jejich vzájemné vzdálenosti.

FRR	< 1 [%]
FAR	0, 1 [%]
rychlost verifikace	3 [s]
míra spolehlivosti	střední

Tabulka 4 Parametry geometrie tváře

3.4.1 *Principy rozpoznávání*

Atraktivnosti rozpoznávání obličejů je z hlediska praktického užívání pochopitelná, ovšem je nezbytné být realistický ohledně vyhlídek této technologie. Doposud neměli obličejové rozpoznávací systémy v praktických aplikacích velký úspěch. Existují dva odlišné přístupy k rozpoznávání geometrie tváře: *geometrický* (založen na rysech tváře) a *fotometrický* (založený na vzhledu tváře). Tři nejlépe prozkoumané a studované algoritmy rozpoznávání tváře jsou následující.

Analýza hlavních částí – PCA

PCA (Principal Components Analysis) využívá vektorů tváře odvozených z kovariační matice pravděpodobnostní distribuční funkce k vytvoření šablony vhodné pro srovnávání. Každá tvář lze rozdělit na tzv. eigenfaces (vzory tváří – matice jasových úrovní) a poté jde opět složit. Každá eigenfaces je reprezentována pouze číslem, takže se namísto obrázku ukládá pouze číslo.

Lineární diskriminační analýza – LDA

LDA (Linear Discriminant Analysis) je metoda, kdy se třídí pořízené obrazy tváří do skupin. Cílem je maximalizovat rozdíly mezi jednotlivými skupinami a minimalizovat rozdíly v každé skupině, každý blok snímků reprezentuje jednu třídu.

Elastický srovnávací diagram – EBG

EBGM (Elastic Bunch Graph Matching) Byla vyvinuta, jelikož předešlé metody nemohou uvažovat nelineární charakteristiky jako je osvětlení okolí, pozice hlavy anebo výraz tváře (úsmev, zamračení). Na obličejích se definují uzlové body, které se poté propojí a tím definují linie tváře v prostoru, vznikne tím souřadnicová síť obličeje. Samotné rozpoznávání pak probíhá tak, že systém pomocí filtru uzlových bodů reaguje na jednotlivé snímané tváře a může je pak porovnávat a vyhodnocovat. Problém je přesnost lokalizace orientačních bodů na tváři, řešením může být kombinace s PCA nebo LDA metodou.

3.4.2 Nepřesnosti detekce

Systémy, které jsou schopny poznávat tváře, omezují rozsah možného správného výběru na třetinu všech možných kandidátů pozitivní identifikace. Jestliže je tvář osoby vyfotografována venku, a to z úhlu 45 stupňů, typický automatizovaný systém selhává v 80 procentech případů. Vliv má také proměnlivost osvětlením způsobovaná odlišností oblečení, vede k tomu, že ve 40 procentech případů nedokáže systém danou osobu identifikovat na základě uložené fotografie. Tato technologie může být nápomocná při prohledávání databází fotografií osob, ale fotografie musejí obsahovat záběr celé tváře a musí být k dispozici dostatečné množství manuálních pracovníků, kteří budou schopni spojit fotografii jedince s fotografií v databázi.

[3]

3.5 Duhovka oka

Automatické biometrické systémy pro rozpoznávání duhovky lidského oka jsou relativně nově vyvinuté. První patent je datován k roku 1994. Duhovka je sval uvnitř oka, který reguluje velikost čočky (zaostření oka) na základě intenzity světla dopadajícího na oko. Duhovka je barevná část oka, jejíž zbarvení odpovídá množství melaninového pigmentu uvnitř svaloviny. Ačkoliv je zbarvení i struktura duhovky geneticky závislá, její vzorkování není. Duhovka se vyvíjí během prenatálního růstu plodu, její vzorkování je čistě nahodilé, tudíž jedinečné pro každého člověka i dvojčata, dokonce i jeden člověk má každou duhovku jinou, což činí tyto systémy nejpřesnějšími ze všech.

FRR	0,00066 [%]
FAR	0,00078 [%]
rychlost verifikace	2 [s]
míra spolehlivosti	vysoká

Tabulka 5 Parametry duhovky oka

3.5.1 *Princip rozpoznávání*

Závěrečná práce se bude dále zabývat biometrickou identifikací podle oční duhovky, proto budou další postupy rozpoznávání osob rozebrány v následující kapitole. V principu je však postup následující. Digitální kamerou se pořídí snímek duhovky oka, který je dále softwarově převeden do odstínů šedi. Zbarvení duhovky je do jisté míry geneticky závislé, jak je již zmíněno výše, a okolní podmínky pro pořizování snímku mohou být různé, nebere se tedy zbarvení duhovky v potaz. Převedení snímku do odstínu šedi také nahrává rychlejšímu pracování s pořízenými daty, jelikož se tím vypustí jedna dimenze matice z pořízeného zdigitalizovaného snímku. Dále se na snímku provádí úpravy jako detekce duhovky, následný ořez okolí duhovky (z důvodu redundance dat), transformace jasu, detekce hran převedení do jakési mapy duhovky, která pak slouží jako hledaný údaj v databázi.

[3]

3.6 Sítnice oka

Pro rozpoznávání osoby podle její sítnice oka se používá obraz struktury cév na pozadí lidského oka v okolí slepé skvrny. Sítnice je světlo-citlivý povrch na zadní straně oka a je složena z velkého množství nervových buněk.

FRR	< 10 [%]
FAR	0,0001 – 0,00001 [%]
rychlost verifikace	0,2 – 1 [s]
míra spolehlivosti	vysoká

Tabulka 6 Parametry sítnice oka

3.6.1 *Princip*

Pro získání obrazu se používá zdroj světla s nízkou intenzitou záření a opto-elektrický systém (dnes se již používá pouze jedna infračervená LED dioda, což snižuje riziko nebezpečného ozáření oka oproti používání systému několika LED diod). Naskenovaný obraz je poté převeden do podoby 40 bitového čísla. Verifikace sítnice je velice přesnou metodou identifikace. Její používání vyžaduje od uživatele, aby se díval do přesně vymezeného prostoru, což může být pro některé osoby nepříjemné a někdy až nemožné, pokud používají brýle.

[3]

3.7 Hlas a řeč

Biometrická identifikace podle hlasu patří mezi nejstarší metody. Již několik desetiletí se využívá v kriminalistice a začíná se prosazovat i v komerční oblasti. Lidský hlas vytváří řečové orgány neboli vokální trakt. Tvoří ho hlasivky, ústní dutina, jazyk a zuby. Jedinečnost je způsobena nejen odlišným tvarem těchto orgánů, ale také subjektivní osobností mluvčího (barva hlasu, rytmus, atd.), akustickou strukturou, gramatikou a skladbou řeči. Díky tomuto je hlas jednotlivce dostatečně výjimečný. Je nutné podotknout, že u této metody je značný rozdíl mezi

pojmy identifikace a verifikace. Identifikace porovnává s databází vyřčené slovo, a pokud odpovídá výslovnosti, je povolen přístup do systému. Naproti tomu verifikace porovnává míru shody mezi vyřčeným slovem a uloženým vzorkem otisku hlasu.

FRR	0,01 [%]
FAR	0,28 [%]
rychlost verifikace	0,2 – 1 [s]
míra spolehlivosti	nízká

Tabulka 7 Parametry hlasové stopy

3.7.1 Princip hlasové detekce

Při vytváření etalonu neboli otisku hlasu se může využít pouhý mikrofon. Ze zvukového záznamu se za pomoci filtrů potlačí nepotřebný okolní šum a rušivé artefakty, čímž se získají jedinečné znaky vokálního traktu, jež tvoří vlastní biometrický vzorek. S ohledem na větší odolnost se volí věty, které obsahují více akustických informací než jednotlivé slovo. Volbou vlastní věty se dále zvyšuje bezpečnost, protože ani sebelepší imitátor není schopen vědět jakou větu má vyslovit. Věty se volí nejčastěji o délce 3 vteřin, jako kompromis mezi paměťovou náročností a dostatkem unikátních informací.

[3]

3.8 Dynamika podpisu

Rozpoznávání osob podle dynamiky podpisu je relativně mladá metoda datovaná k roku 1977. Tato metoda využívá jedinečností kombinace anatomických a behaviorálních vlastností člověka, když se podepisuje. Zařízení na dynamický podpis se často mylně zaměňuje s pojmy elektronický podpis (šifrovaný klíč) nebo se zařízeními na snímání podpisu jako obrazu. Z ručního podpisu lze tak elektronicky zjistit tah, tvar a tlak při psaní, což lze použít pro verifikaci osoby. Jednotlivé druhy zařízení se liší dle výrobce způsobem užití a jeho významem, ale mají shodnou vlastnost použití technologií citlivých na dotek, tedy PDA záznamníků nebo digitalizačních tabulí. Většina těchto zařízení využívá dynamických vlastností podpisu, ačkoliv existují i kombinace se statickými a geometrickými vlastnostmi podpisu.

FRR	0 [%]
FAR	< 0,1 [%]
rychlost verifikace	-
míra spolehlivosti	střední

Tabulka 8 Parametry dynamiky podpisu

3.8.1 *Princip*

Základními dynamickými charakteristikami jsou rychlost, akcelerace, časování, tlak a směr tahu, které jsou zaznamenávány v trojrozměrném souřadnicovém systému. Osy „x“ a „y“ slouží k určení rychlosti a směru tahu, souřadnice „z“ určuje tlak na podložku. Na rozdíl od statického obrazu podpisu, který může být naučen a napodobován, je nemožné se dynamiku podpisu pouze z obrázku naučit. Výhodou je i snadné integrování zařízení do již existujících systémů (stačí PDA a vhodný SW). Naopak nevýhodou je, že tyto systémy jsou schopné zvládat pouze verifikační principy.

[3]

3.9 Chůze

Stejně jako otisk prstu nebo duhovka oka je i pohyb člověka unikátní a svým způsobem nezaměnitelný v relativně širokém časovém období. České kriminalistice a jejímu výzkumu patří přední místo ve světě ve vývoji identifikace člověka podle stylu chůze, tedy „pohybu po dvou nohách“, neboli bipedální lokomoce. Velký podíl na rozvoji této metody má i rozmach záznamové a snímací techniky.

3.9.1 *Princip identifikace dle chůze*

Stejně jako při identifikaci podle ručního podpisu je rozlišovacím znakem jedinců různý dynamický stereotyp. U písma se jedná o stereotyp ruky, na rozdíl od chůze, kde se jedná o stereotyp pohybu celého těla. Svým způsobem jsou si ale velmi podobné. Celé metoda pracuje na základě porovnávání křivek drah, které opisují určité body na lidském těle, tedy hlavně jeho těžiště. Jelikož je každý člověk jedinečný svým pohybovým svalově kosterním systémem a svým dynamickým stereotypem, jsou i křivky uvažovaných bodů unikátní a vhodné pro srovnávání.

[3]

3.10 DNA

Žádný jiný údaj nedokáže tak komplexně charakterizovat člověka jako DNA. DNA neboli kyselina deoxyribonukleová se neliší pouze u jednovaječných dvojčat. Počet rozdílů mezi dvěma nepříbuznými jedinci je přibližně 10^6 . S pomocí DNA lze bezpečně identifikovat každého jedince a zároveň lze ze získaného genetického profilu vyčíst řadu informací o fyzických charakteristikách daného jedince.

3.10.1 *Princip*

Získávání otisků DNA představuje poměrně náročnou a zdlouhavou proceduru, která zahrnuje přibližně pět kroků. Během nichž je ze vzorku tkáně vypreparována nejprve celá spirála DNA, která je následně štěpena enzymem EcoR1 a posléze jsou fragmenty DNA prosévány, až se získá řetězec využitelné velikosti. Získané fragmenty jsou přeneseny na nylonovou membránu a po přidání radioaktivních nebo obarvených genových sond je získán

rentgenový snímek – otisk DNA. Tento otisk připomíná čárový kód, a proto je snadné jej převést do elektronické podoby. Pro kontrolu přístupu v reálném čase vak zatím není tato technologie použitelná.

[3]

4 ANALÝZA A SNÍMÁNÍ OČNÍ DUHOVKY

V této kapitole je stručně popsána anatomie duhovky a dále metody pro snímání oční duhovky a aktuální technologie pro pořízení snímků oční duhovky. V kapitole je uveden pouze teoretický rozbor a porovnání podle parametrů uvedených výrobcí.

4.1 Anatomie oka a oční duhovky

Lidské oko je orgán, který umožňuje jedinci vidět. Opatří mezi nejsložitější orgány v těle a je nejvíce využíváno pro interakci s okolním světem (zrakem vnímáme okolo 90% všech smyslových vjemů). Základní funkce oka je stejná jako u každého detektoru záření. Záření (světlo) projde přes optickou soustavu, je zachyceno detektory, transformováno na signál a ten následně odeslán do části mozku, která jej interpretuje jako obraz.

Oko je mírně protáhlá koule o průměru asi 25mm. Přední část oka je kryta odolnější vrstvou – rohovkou, pod kterou se nachází přední oční komora vyplněná očním mokem. Za rohovkou se vyskytuje oční duhovka, která v oku plní úlohu clony s proměnnou velikostí od cca 2mm do 6mm. těsně za duhovkou se nachází oční čočka s proměnlivou ohniskovou vzdáleností, řízená dvěma svaly.

Vnitřní prostor oka je vyplněn sklivcem (rosolovitá substance s nízkým indexem lomu světla) sloužícím pro udržení konstantního nitroočního tlaku, který udržuje kulovitý tvar oka. V nejvzdálenější části oka se nachází jeho nejdůležitější část – sítnice. Skládá se z velkého množství světločivých buněk – tyčinek a čípků (asi 120 miliónů tyčinek a 6 miliónů čípků). Tyčinky jsou citlivější a jsou více využívány za zhoršených světelných podmínek, nedokáží však ale rozlišit frekvenci dopadajícího světla – jeho barvu. Buňky reagující na barvu jsou čípky.

Místo největší hustoty světlo citlivých buněk na sítnici se nazývá žlutá skvrna (místo, kde vidíme nejostřeji), která se nachází v ose optické ose čočky. Nervové spojení všech tyčinek a čípků se sbíhá do očního nervu, který opouští bulvu v místě slepé skvrny. Je to jediné místo kde sítnice neobsahuje žádné tyčinky a čípky.


Jelikož se diplomová práce zabývá snímání oční duhovky, dále bude uveden anatomický popis už jen pouze oční duhovky.

Oční duhovka je pro jedince unikátní částí oka tak, že i jednotlivé duhovky osoby se navzájem liší. Duhovka je kruhovou částí oka s vláknitou strukturou. Viditelná je pouze přední část, která je tvořena předním listem (stromou). Skládá se z kolagenních, elastických a svalových vláken protkaných cévami. Uspořádání vláken odpovídá uspořádání cév a je protkáno prohlubněmi – lakunami a kryptami.

Uprostřed duhovky se nachází průhledné místo – zornice (panenka, pupila). Její průměr je kontrolován dvěma svaly musculus sphincter iridis, který zornici smršťuje, a musculus dilatator iridis, který naopak zornici rozšiřuje. Oba vykonávají svou úlohu reflexivně v závislosti na intenzitě dopadajícího světla nebo pod vlivem omamných látek.

Jak již bylo výše vícekrát zmíněno, duhovka je jedinečná pro každou osobu, dokonce ani obě duhovky jedné osoby nejsou identické. Její struktura se formuje v prenatálním období zhruba ve třetím měsíci vývoje plodu a je ukončena v osmém měsíci. Během života se duhovka nemění, je snadno přístupná a není ovlivněna vnějšími vlivy – mechanické poškození zasáhne ve velké většině případů pouze rohovku. Studie zabývající se využitím duhovky jako biometrického znaku uvádějí 266 pozorovatelných příznaků a entropii 3,2 bitu na čtvereční milimetr duhovky.

[8]



Obrázek 1Anatomie duhovky [21]

4.2 Základní metody pro snímání oční duhovky

Základní metody pro snímání oční duhovky se de-facto dělí na dvě hlavní skupiny. Jako první skupinou se může uvádět postup, kdy si je jedinec vědom o pořizování snímku jeho biometrické informace. Takto můžeme uvažovat např. zaměstnanec přihlašující se do interního systému docházky ve firmě, cizinec procházející pasovou kontrolou, lékař vstupující na

oddělení s omezeným přístupem atd. Jde o přístup, který nevyžaduje příliš drahé zařízení s vysokou pořizovací kvalitou snímku.

Oproti tomu druhá skupina pojednává sejmутí oční duhovky bez vědomí daného jedince. Tato metoda přichází v úvahu při detekci jedinců v určitém davu lidí nebo při utajeném sledování osob.

4.2.1 Snímání s vědomím jedince

Jedná se o metody kooperativní, tzn. jedinec se sejmутí snímku souhlasí. Testovaná osoba ví, kde se snímací zařízení nachází, a vlastním vědomím nechává pořídit snímek. Příkladem může být omezený přístup do určitých bezpečnostních zón firmy, banky, nemocnice.. V případě chybného pořízení snímku je snadné opakování celého procesu a pořízení nového snímku.

Je možné používat větší snímače s horšími technickými parametry. Výstupem bude vždy snímek podle potřeb použitých zpracovávajících metod (viz další podkapitoly). Pro usnadnění uživatelské přístupnosti celého systému tvoří snímací zařízení jeden celek spolu s fixátorem hlavy. Fixátorem hlavy je myšleno anatomicky tvarované místo, kam se přiloží obličej jedince, což eliminuje případné otřesy při pořizování snímku a zajistí vždy téměř přesně danou polohu oka (a tím i oční duhovku) jedince ve výsledném obraze. Celý proces se tím zjednoduší a výstupní snímek může být připraven přesně podle potřeby zpracovávajícího algoritmu v co možné nejvyšší kvalitě snímku.

4.2.2 Snímání bez vědomí jedince

Pořizování snímků oční duhovky bez vědomí daného jedince je mnohem složitější s vyššími HW i SW nároky. Komerční využití této metody zatím není ve fázi běžného používání např. letištní bezpečnostní služby, provádí se ale experimentální testování a v brzké době se může objevit možná právě na zmiňovaných letištích. Tato metoda slouží hlavně k detekování „významných“ osob v davu, v budoucnosti nejspíše většinou pro potřeby ochranných složek. Při chybném pořízení snímku se nemůže proces opakovat, oko není správně namířeno na snímač a snímek je pořizován z velké vzdálenosti. Tato skutečnost navazuje na nutnost vybavenosti CCD snímačů o velikém rozlišení, řádově stovky mega pixelů. Základní myšlenka vychází z metody detekce obličeje. Algoritmy detekující obličej dané osoby jsou schopny lokalizovat jednotlivé části obličeje (oči, ústa, nos). Z těchto určitých částí lze vyparovat snímek oční duhovky a ten dále použít k identifikaci.

[3]

4.3 Zpracování snímků oční duhovky

Analýza oční duhovky je komplexní proces skládající se typicky ze čtyř částí: segmentace, normalizace, extrakce příznaků a porovnávání příznaků. Podobně jako u

rozpoznávání jiných objektů – hlasu, písma, otisků prstů – se jednotlivé metody liší implementací zmíněných kroků zvolených pro dosažení optimálních výsledků.

Každá z těchto částí vyžaduje aplikaci speciálních metod a postupů. Kombinováním různých přístupů k dané problematice dalo vzniknout několik nejznámějších komplexních metod pro analýzu oční duhovky, které se používají v komerční sféře. Avšak do dnešních dnů se stále neopouštějí původní postupy vyvinuté Daugmanem na počátku 80. let 20. století.

[3]

4.4 Předzpracování snímků

Snímek pořízený ze snímače obsahuje množství artefaktů (šum, barevná nejednotnost, rozmazání), které nepříznivě ovlivňují další zpracování a vlastní rozpoznávání. Některé zdroje nepovažují předzpracování snímku za nutnost, jelikož uvažují pořizování snímků v ideálních okolních podmínkách. Správné předzpracování snímku však může značně zvýšit spolehlivost celého systému.

Prvním krokem, pokud snímač pořizuje snímky s barevnou složkou (tří dimenzionální matice), je převod barevné palety do odstínů šedi. Tímto krokem se zredukuje drobné odchylky v barevných tónech způsobené CCD snímačem. Jednotlivé světločivé prvky nikdy nezaznamenají přesně stejný barevný odstín, i když jsou zaměřeny na stejný bod. Dále pro efektivnější zvýraznění hran je nutno normalizovat barevné spektrum snímku, což by se nemělo zaměřovat s jedním z následujících kroků úpravy snímků, nazvaným také normalizace.

[3]

4.4.1 *Normalizace šedotónové variace*

Pro normalizaci šedotónové variace (rozptyl hodnot obrazových bodů od jejich průměru) nepracujeme s celým snímkem, ale s nepřekrývajícími se bloky, na které musíme snímek rozdělit. Celý snímek nemusí mít stejnou strukturu, jsou na něm místa s malou variací (nejčastěji pozadí) a místa s velkou variací (hledané objekty).

Pro každý blok o velikosti W ze snímku IM si spočteme průměrnou hodnotu jasu M a variaci V podle vztahů:

$$M = \frac{1}{W^2} \sum_{i=0}^{W-1} \sum_{j=0}^{W-1} Im(i,j) \quad (1)$$

$$V = \frac{1}{W^2} \sum_{i=0}^{W-1} \sum_{j=0}^{W-1} (Im(i,j) - M)^2 \quad (2)$$

Normalizovaný obraz poté vypočteme podle vztahu

$$N(i, j) = \begin{cases} M_0 + \sqrt{\frac{V_0}{V}} (Im(i, j) - M)^2; & \text{pro } Im(i, j) > 0 \\ M_0 - \sqrt{\frac{V_0}{V}} (Im(i, j) - M)^2; & \text{jinak} \end{cases} \quad (3)$$

kde $N(i, j)$ je normalizovaná šedotónová hodnota pixelu (i, j) , $Im(i, j)$ je hodnota pixelu v původním snímku, M střední hodnota v daném bloku, V variace daného bloku, M_0 požadovaná střední hodnota a V_0 je požadovaná variace.

4.4.2 Ekvalizace snímků a redukce úrovní jasu

Metoda sestávající se ze dvou kroků, která dosahuje dobrých výsledků ve zvýrazňování hran objektů. Prvním krokem je ekvalizace histogramu snímku, aby se docílilo rovnoměrného rozložení hodnot jasů. Druhým krokem je redukce počtu jasových úrovní ve snímku.

Ekvalizace histogramu snímku je používána pro zvýšení lokálního kontrastu, pokud máme ve snímku blízké hodnoty jasu. Celý proces je jednoduchý a výpočetně nenáročný. Vycházíme z histogramu snímku, který není rovnoměrně rozložený a jeho hodnoty jsou v rozsahu $<0;1>$. Z něj si vypočteme histogram kumulativní:

$$c(i) = \sum_{j=0}^i p(x_j), \quad (4)$$

kde $p(x_j)$ je hodnota sloupce histogramu pro jas s indexem j . Dále je potřeba funkce transformující stávající hodnotu jasu tak, aby byl histogram nově vzniklého snímku co nejrovnoměrněji rozložen. Díky malému počtu jasových úrovní se tato funkce definuje nejčastěji tabulkou, jejíž hodnoty určíme podle vztahu:

$$y_i = c(i) \quad (5)$$

Nakonec se transformuje hodnota jasu z hodnot o rozsahu $<0;1>$ do plného rozsahu jasů (rozsah $< \min; \max >$) užitím vztahu:

$$\hat{y}_i = y_i(\max - \min) + \min \quad (6)$$

Tímto postupem se získá snímek s rovnoměrně rozloženými hodnotami jasů a s vyšším kontrastem. Jako druhý krok snížíme počet jasových úrovní. Tento postup je jednoduchý, určí se pouze počet úrovní a metodu redukce. Pro počet úrovní p a metodu redukce k nižšímu prahu získáme novou hodnotu jasu dle vztahu: [3]

$$\hat{y}(x, y) = \text{floor}\left(\frac{IM(x, y)}{p}\right) \quad (7)$$

4.5 Segmentace

Účelem segmentace je zajistit, kde se nachází duhovka a zřítelnice. Kvůli aplikaci výpočetně složitých transformací se jedná o jednu z nejpomalejších částí analýzy. Pro vlastní zjištění kde se nachází duhovka (popřípadě zřítelnice), musíme zjistit všechny hrany nacházející se v obrázku. Pro detekci hran existuje několik algoritmů, použitelných pro zpracování obrazů v reálném čase. Nejpoužívanější je Canneho a Sobelův detektor hran, oba jsou založeny na zkoumání gradientu sousedních pixelů. Canneho detektor lze lépe nastavit pro konkrétní případy, Sobelův oproti tomu detekuje spolehlivěji ale je citlivější na šum.

Jakmile se vyhledají ve snímku hrany, aplikují se postupy pro detekci jednoduchých geometrických obrazců ve snímku. Většina těchto postupů prochází postupně všechny nalezené hrany a testuje, jestli jejich kombinace nevytváří daný obrazec. Pro výpočetní náročnost takového postupu jsou v praxi využívány jejich modifikace, založené na heuristických postupech.

4.5.1 Sobelův detektor hran

Fungování Sobelova detektoru hran je založeno na Sobelovu operátoru, který je tvořen dvěma maticemi. Operátoru lze rozumět jako gradientní přechod zleva doprava a shora dolů. Vlastní operátor tvoří dvě matice rozměru 3x3, jež jsou zpracovány pomocí konvoluce s původním obrázkem.

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} * A; \quad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix} * A \quad (8)$$

kde G_x je matice pro aproximaci derivace v ose x (směr zprava doleva), G_y matice pro aproximaci derivace v ose y (směr shora dolů), a A je matice původního obrázku. Pro každý bod obrázku se vypočte gradient podle vztahu:

$$\Phi = \arctan \frac{G_y}{G_x} \quad (9)$$

Hodnoty tohoto gradientu v jednotlivých bodech udávají možnost výskytu hrany (čím je hodnota větší, tím je přechod ostřejší a opačně). Pro případné citlivější nastavení je nutné nastavit jiné hodnoty v maticích Sobleova operátoru, které tak budou zkoumat Větší úhel gradientu. Obecně je tento detektor citlivější na šумы a ruchy v obrázku, jež může způsobit zařízení digitalizující obraz (scanner, digitální fotoaparát).

4.5.2 Canneho detektor hran

Canneho detektor podobně jako Sobelův vychází ze zkoumání gradientů vedle sebe ležících pixelů. Na rozdíl od Sobelova operátoru filtruje matici obrázku lépe nastavitelným operátorem, založeným na první derivaci Gaussovy funkce. Tím by měl eliminovat drobné šумы v obrázku a detekovat pouze hrany. Změnou šířky jádra Gaussovy funkce navíc reguluje pravdivost, zda je získaná hrana opravdu hrana, získané hrany, tj. porovnává gradient u většího počtu sousedů a dává tak větší pravděpodobnost o existenci hrany.

Matice s hodnotami první derivace Gaussovy funkce je použita jako filtr, který je pomocí konvoluce zpracován s původním obrázkem. Na příklad matice o rozměru 5x5 pro Gaussovu funkci s jádrem $\sigma = 1,4$ vypadá následovně

$$B = \frac{1}{159} \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix} * A \quad (10)$$

Jelikož je gradient schopen směřovat v rozličných směrech, Canneho detektor využívá čtyři filtry. Každý pro detekci v horizontálním, vertikálním a po obou diagonálních směrech. Výstupem je bitmapa gradientů – potenciálních hran. Vyhodnocení výsledku se provede prahováním s hysterezí. Větší rozsah získaných gradientů umožňuje lépe zvolit vhodnější hrany. Definují se konstanty udávající horní a dolní hranici hysterze (číselné hodnoty gradientů) a do výstupu se použijí pouze hodnoty, které se nachází mezi hodnotami těchto konstant. Bohužel určení těchto hodnot a hodnot pro Gaussův filtr není triviální. Zároveň je to však mocný nástroj, jež činí Canneho detektor hran mnohem použitelnějším, pokud se podaří experimentálně nastavit správně jeho parametry.

4.5.3 Houghova transformace

Houghova transformace udává nejobecnější postup, jak najít v obrázku geometrické útvary (čáry, kruhy atd). Pro účely analýzy oční duhovky bude popsána kruhová Houghova transformace detekující kružnice.

Tato metoda vychází z myšlenky průchodu celým obrazovým prostorem a porovnáváním tam se nacházejících bodů s určitým hledaným obrazem vzoru (kružnicí). Z takto nalezených množin bodů vybírá maxima, která značí největší pravděpodobnost výskytu daného obrazce (kružnice). Při vykreslení výsledné transformace představují tato místa nejtmavší body.

V případě kruhové Houghovy transformace se hledají kružnice definované vztahem $x^2 + y^2 - r^2 = 0$. Pokud však hledáme nejpravděpodobnější výskyt všech kružnic o všech možných poloměrech, je složitost tohoto algoritmu $O(n^3)$. Detekce je však spolehlivá a funguje i pro části kružnic. Bohužel výpočetní složitost zatěžuje nasazení této metody na starších a pomalejších strojích. Dalším problémem kruhové Houghovy transformace je výpočet bodů kružnice, která je vyhledávána. Klasický přístup pomocí goniometrických funkcí je příliš pomalý a zvyšuje složitost výpočtu až k $O(n^4)$. Používají se tedy zde Bresenhamovy algoritmy. Popisují každý bod v pravoúhlém rastru všech matematicky popsatelných křivek (kružnice, čára, atp). Algoritmy vycházejí z matematických definic těchto křivek a jejich případné symetrie.

4.5.4 Daugmanův operátor

Daugmanův operátor je vlastně speciální případ Houghovy transformace. Byl navržen přímo pro Daugmanovu metodu rozpoznávání. Kvůli citlivosti Houghovy transformace na šum v obrázku (množina náhodných bodů tvořících šum se může tvářit jako body kružnice). Operátor je definován jako

$$\max_{r, x_p, y_0} \left| G_\sigma(r) * \frac{\delta}{\delta r} \int_{r, x_p, y_0} \frac{l(x, y)}{2\pi r} ds \right| \quad (11)$$

kde $l(x, y)$ je matice tvořící obrázek, r poloměr vyhledávané kružnice, G_σ Gaussova funkce a s množina bodů tvořícího kruh zadaný parametry r, x_0, y_0 .

Na rozdíl od Houghovy transformace pracuje Daugmanův operátor s informací první derivace pro nalezení obrazových bodů. Netrpí proto takovou citlivostí na šum jako Houghova transformace. Bohužel pracuje také s hodnotou určitého integrálu, který jde sice vypočítat přesně aplikací numerických metod, avšak tento výpočet je poměrně náročný. Hledání kružnice tak může dosahovat při prohledávání celého obrazového prostoru složitosti i $O(n^5)$, protože numerický výpočet integrálu má složitost $O(n^2)$, prohledávání celého obrazového prostoru $O(n^3)$. Jde však optimalizovat snáze než Houghova transformace, z toho důvodu je také využíván v některých metodách analýzy oční duhovky.

4.5.5 Metody rychlé detekce

Oba výše uvedené postupy založené na principu Houghovy transformace jsou ale pro většinu použitých snímků nepoužitelné kvůli vysokým nárokům na výkon počítačové soustavy. Bylo zveřejněno několik metod, zabývajících se snížením výpočetní náročnosti Houghovy transformace, při zachování stávající spolehlivosti. Nejlépe se však jeví využití metody gradientního páru vektorů.

Základním principem metody rychlé detekce kružnic s využitím gradientního páru vektorů vychází z charakteristik gradientních vektorů bodů ležících na obvodu kružnice. V případě tmavě vyplněného kruhu na světlém pozadí tak gradienty směřují vždy ze středu kružnice. Jsou-li známy gradientní vektory (v_1 a v_2), lze určit střed kružnice, pokud jsou zachovány následující podmínky:

- úhel svírající v_1 a v_2 je blízký 180 stupňům
- úhel svírající spojnice základů v_1 a v_2 by měl být blízký 0 stupňům

Samotný algoritmus se sestává ze tří kroků, za předpokladu, že už je vytvořen, gradientní snímek. Nejprve se vytvoří všechny možné kombinace nalezených vektorů tak, aby byly zachovány výše uvedené podmínky. Dále se pro každý takovýto pár stanoví odhadovaný střed kružnice (dle definice tvořen průsečíky vektorů) a odhadovaný poloměr (vypočtený pomocí odhadovaného středu).

Nakonec v poslední fázi podobně jako u Houghovy transformace je nutné si zvolit kružnici s největší pravděpodobností. Jde použít „hrubé“ síly jako u Houghovy transformace, což znamená hledání maxima ve trojrozměrné matici, nebo je možné uchovávat pro každou dvojici vektorů v_1 a v_2 příznakový vektor obsahující souřadnice středu kružnice a její poloměr. Nejčastěji se opakující hodnoty jsou uvažovány jako kružnice.

[3]

4.6 Normalizace

Je dokázáno, že oční duhovka a zřítelnice nemusejí být soustředné kružnice. Může to být způsobené samotnou fyziologií člověka nebo vlivem optické deformace, pokud se snímané oko nenachází v optické ose snímače. Nesoustřednost však ztěžuje normalizace získaného obrazu do použitelného vektoru příznaků. V případné existenci soustřednosti by stačilo pouze převodem kartézských souřadnic na polární získat dvourozměrný vektor libovolné přesnosti, bohužel je třeba použít mírně komplikovanějších metod založených na převodu do jiného souřadného systému. Základní přepis souřadnic je definován jako

$$l(x(r, \phi), y(r, \phi)) \rightarrow l(r, \phi) \quad (12)$$

kde $x(r, \Phi)$ a $y(r, \Phi)$ jsou souřadnice bodu obrázku v kartézských souřadnicích, $l(r, \Phi)$ je souřadnice bodu obrázku v kartézských souřadnicích, $l(r, \Phi)$ je souřadnice stejného bodu v polárních souřadnicích. Jednoduchý přepočít lze definovat jako

$$r = (x_0 + r_0 \cos(\Phi_0)); \Phi = (y_0 + r_0 \sin(\Phi_0)) \quad (13)$$

kde Φ_0 je z intervalu $(0; 2\pi)$, r_0 je právě zpracovávaný poloměr. R a Φ jsou výsledné polární souřadnice.

4.6.1 Daugman rubber sheet

Jedná se o jednu z nejpoužívanějších metod normalizace duhovky navrženou přímo pro Dougmanovu metodu analýzy oční duhovky. Základní myšlenkou metody je převod kruhové oční duhovky z kartézského souřadného systému do polárního souřadného systému, přičemž si poradí i s nesoustředností duhovky a zřítelnice. Tímto krokem se získá z nepoužitelné kruhové oblasti použitelná pravoúhlá dvourozměrná matice. Daugman navrhl metodu, která rozděluje duhovku na 10 pásů. Tyto pásy nejsou soustředné, jejich střed se pohybuje na spojnici středu zřítelnice (středu duhovky). Následným převodem těchto pásů do polárního souřadného systému se dají získat deset vektorů, které se složí v jednu normalizovanou matici příznaků.

[3]

4.7 Extrakce příznaků

Pro extrakci příznaků z normalizovaného vektoru se používají metody analýzy jednorozměrného signálu aplikované na dvourozměrný vektor. Smyslem těchto metod je odstranit šum, řasy a podobné rušivé artefakty. Získáme tak jednoznačný vektor příznaků, unikátní pro každého jedince a oční duhovku. Jdou vesměs použít všechny známé metody určené pro zpracování signálu. Uvedená je základní myšlenka několika transformací, které jsou využity dále, v popisu některých komplexních metod analýzy oční duhovky.

4.7.1 Gaborův filtr

Gaborovy filtry představují reprezentaci signálů v prostoru a v závislosti na frekvenci. Je vytvářen modulací sinových a cosinových vln s Gaussovou funkcí. Sinové vlny jsou totiž charakteristické pro frekvenci, použitím modulace Gaussovou funkcí získáme charakteristiku pro prostor. Pro zjednodušení zápisu těchto filtrů se používá exponenciální tvar komplexního čísla, pro příklad 2D-Gaborovy filtry použité pro extrakci příznaků v Daugmanově metodě

$$G(x, y) = e^{-\pi(\frac{(x-x_0)^2}{\alpha^2} + \frac{(y-y_0)^2}{\beta^2})} e^{-2\pi i(u_0(x-x_0) + v_0(y-y_0))} \quad (14)$$

kde α, β jsou šířka a délka filtru, u_0, v_0 jsou specifikátory modulace a platí pro ně, že frekvence $w_0 = \sqrt{u_0^2 + v_0^2}$. Ve většině případů se reálná část výše uvedeného komplexního

tvaru Gaborových filtrů používá jako vlastní biometrický příznak, reálná část jako doplňující hodnota pro upřesnění v případě dvou podobných porovnávaných příznaků.

4.7.2 Gaussův filtr

Přesněji se jedná o Laplaceův operátor Gaussova filtru definovaného jako

$$F = -\frac{1}{\pi\sigma^4} \left(1 - \frac{\rho}{2\sigma^4} e^{\frac{\rho^4}{2\pi r^2}} \right) \quad (15)$$

kde σ je derivace Gaussovske funkce a ρ je vzdálenost bodu od středu filtru. Získaný normalizovaný vektor příznaků je iterativně segmentován pomocí dolní propusti na dva koeficienty pro každou dimenzi jeden. Tato reprezentace je posléze použitelná jako jednoznačný biometrický identifikátor.

4.7.3 Vlnková transformace

Vlnková transformace (angl. wavelet transformation) je obdobně jako Fourierova transformace používána pro vytvoření frekvenčního popisu s rozdílem, že je možno popsat změnu frekvence v čase. Je tedy vhodná na zpracování nestacionárního signálu. Lze ji využít pro výpočet unikátního příznakového vektoru z biometrických dat oční duhovky.

Principem vlnkové transformace je analýza signálu na jednotlivých úrovních, kde každá úroveň má větší vypovídající schopnost o menším úseku daného signálu a tím i vyšší lokální přesnost. Snažíme se vhodně měnit šířku okénka, abychom lépe zachytili časově-frekvenční změny. Toto proměnné okénko tvoří funkce nazývaná mateřská vlnka

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (16)$$

kde měřítko (roztážení) je určeno parametrem a , posun je určen parametrem b . Na vlastní mateřskou vlnku jsou kladeny požadavky. Musí mít nulovou střední hodnotu a nenulovou hodnotu musí mít pouze v omezeném intervalu.

Vlnková transformace spojitého signálu $f(t)$ je definována jako:

$$W_\Psi = \int_{-\infty}^{+\infty} f(t) \Psi_{a,b}(t) dt \quad (17)$$

Postupnou aplikací tohoto vztahu získáme jednotlivé koeficienty vyjadřující časově-frekvenční popis signálu. Tyto koeficienty jsou dále použitelné jako příznakový vektor. [3]

4.8 Porovnávání příznaků

Porovnávání příznaků je posledním krokem biometrického systému. Lidská duhovka má unikátní strukturu, kterou není možno zachytit vždy stejně (díky vlivu prostředí, šumu snímače, světelných podmínek, lidského faktoru atp), počítače však porovnávají velmi přesně bit po bitu. Ačkoliv se snažíme příznakový vektor co nejvíce zobecnit (a neztratili přitom unikátnost pro každou osobu), nikdy nezískáme dvě naprosto stejné hodnoty a musíme se spokojit pouze s vysokou pravděpodobností podobností.

Pro porovnávání příznaků lze použít několik metod. Efektivita a rychlost zvolené porovnávací metody se liší v závislosti na použité metodě extrakce příznaků. Pro některé metody extrakce stačí použít pouhé porovnání na základě Hammingově vzdálenosti vektorů, pro další je zase třeba sofistikovanějších porovnávacích algoritmů.

4.8.1 *Hammingova vzdálenost*

Hammingova vzdálenost je nejjednodušší metoda, jak porovnat dva vektory a číselně určit jejich vzdálenost. Udává počet rozdílných prvků vektoru. Pro svou jednoduchost je Hammingova vzdálenost užívána v řadě odvětví od kódování signálu až po porovnávání příznakových vektorů oční duhovky.

Pro aplikaci Hammingovy vzdálenosti musí mít oba porovnávané vektory stejnou velikost a stejný datový formát. Dále v rámci zjednodušení výsledku se bude počítat procentuální rozdíl, vydělíme vypočtenou Hammingovu vzdálenost celkovým počtem prvků. Vzorec pro výpočet hodnoty bude vypadat následovně

$$HD_{proc} = \frac{1}{N} \sum_{i=1}^N X_{porovnávaný} XOR X_{vzor} \quad (18)$$

Pro užití v metodách porovnávání příznakových vektorů oční duhovky je HD upravena o posun vzorových vektorů. I když jsou algoritmy pro lokalizaci a normalizaci oční duhovky přesné, vlivem kvantizace a vnějších podmínek (natočení hlavy) mohou snadno vzniknout příznaky posunuté o několik bitů. Jedná se o vícekrokové porovnávání, kdy v každém kroku simulujeme otočení duhovky o dva stupně, celkem tedy 180 kroků na porovnávání dvou příznakových vektorů, rotace je simulována bitovým posunem každého řádku příznakového vektoru. Pro jemnější rozlišení není prováděna rotace z důvodů výpočetní složitosti. Získaný algoritmus by byl neřešitelný v reálném čase se složitostí $O(N^N)$.

4.8.2 Korelace signálu

Jelikož se k získanému příznakovému vektoru během jeho získávání často přistupuje pomocí metod zkoumání signálu (FT, signálové filtry atp), může se pro jeho porovnávání taktéž použít metody, původně určené pro porovnávání signálů. Nejpoužívanější je metoda korelace signálu. Výsledkem korelace je číslo určující stupeň podobnosti dvou signálů, je definována jako:

$$R_{f,g}(t) = \int f * (\tau)g(t + \tau)d\tau = \int f * (\tau - t)g(\tau)d\tau \quad (19)$$

kde proměnná t určuje časový posun signálu. Pro analýzu oční duhovky je dále využívána modifikace zvaná autokorelace, která určuje periodicitu signálu (jak je signál podobný sám sobě) a pomůže nám určit rotaci vzoru oproti porovnávanému obrazu. Nejčastěji je využívána autokorelace prvního řádu (tj. první prvek s druhým, druhý se třetím atd), autokorelaci k -tého řádu definujeme jako:

$$R_k = \frac{\sum_{i=1}^{n-k}(x_i - \bar{x})(x_{i+k} - \bar{x})}{\sum_{i=1}^n(x_i - \bar{x})^2} \quad (20)$$

[3]

4.9 Metody analýzy oční duhovky

Na základě výše uvedených a popsáných kroků bylo vytvořeno mnoho metod řešících komplexní problematiku analýzy oční duhovky. Mnoho těchto algoritmů je použito v komerční sféře a není známa jejich konkrétní podoba. Pro přehled je zde uvedeno několik metod, které byly zveřejněny a které jsou v praxi využívány.

4.9.1 Daugmanova metoda

Daugmanovou metodou pro výše popsané části procesu zpracování snímku duhovky je využíván následující postup:

- Pro segmentaci duhovky navrhl Daugman vlastní integračně-diferenciální operátorem který hledá maximální diferenci mezi průměrnými hodnotami jasu. Tento operátor byl již popsán výše.
- Pro segmentaci duhovky a zřetelnice je pro normalizaci použit proces převodu z kartézských na polární souřadnice, známý jako Daugman rubber sheet method, který byl také popsán výše.

- Pro extrakci příznaků jsou použity Gaborovy dvourozměrné filtry.
- Pro porovnávání vektorů příznaků je v této metodě zvolena Hammingova vzdálenost. Výpočet probíhá pomocí funkce XOR. Hledá se minimální hodnota Hammingovy vzdálenosti pro každé dva vektory, uložené v databázi pro porovnávání.

[6]

4.9.2 Wildesova metoda

Wildes popsal specifickou metodu vhodnou pro automatické zpracování, která je založena na třech částech – pořízení snímku, lokalizace duhovky a porovnávání.

- Pořízení snímku považuje Wildes za nejnáročnější část celého procesu automatického rozpoznávání oční duhovky. Tuto obtížnost zdůvodňuje tím, že pro bezchybný chod potřebují rozpoznávací algoritmy snímky s dostatečným rozlišením, jasně a ostře. Pořízený snímek musí být vycentrován vzhledem ke středu duhovky, musí být potlačeny veškeré obrazové artefakty (světelné odrazy a optické deformace). Kvůli těmto podmínkám požaduje autor pořizování snímků co možná nejvyšší optikou s průměrem alespoň 80mm a na vzdálenost maximálně 20 cm. Tyto hodnoty určil autor experimentálně.
- Lokalizaci duhovky autor rozdělil do dvou částí. Nejprve vytvoří binární mapu hran, založenou na zkoumání gradientu pomocí dvourozměrné Gaussovy funkce (metoda podobná Canneho detektoru hran). Pro detekci vlastního tvaru duhovky a zřítelnice je v této metodě použita Houghova kruhová transformace s metodou potlačení vlivu řas.
- Extrakce příznaků je provedena v několika krocích. Nejprve je vektor „zarovnán“ vhodně zvolenými mapovacími funkcemi, pro potlačení změn způsobených translací a rotací jednotlivých markatů ve snímku, také je pomocí této funkce převeden kruh tvořící duhovku na dvourozměrnou matici příznaků. Následuje samotná extrakce příznaků pomocí Laplaceova operátoru Gaussova filtru popsaného výše.
- Porovnávání příznaků je provedeno postupnou korelací mezi všemi položkami databáze a právě získaným příznakem vektorem. Výsledek, pravděpodobnost, je vyhodnocen užitím Fisherova lineárního diskriminantu jako odpověď ANO/NE.

[5]

4.9.3 Maova metoda

Maova metoda je jedna z novějších metod, jedná se o metodu poskládanou z již známých a osvědčených částí, které byly použity v metodách předchozích. Metody analýzy jsou následující:

- Lokalizace oka je podobně jako výše popsané Wildesovy metody založena na vytvoření binární mapy hran a následně na vyhledávání kružnic Houghovou transformací.
- Pro normalizační proces použili autoři stejnou metodu jako použil Daugman ve své metodě, Dougman rubber sheet method. Je použita primárně kvůli potlačení různého roztažení zřítelnice v závislosti na osvětlení a denní době.
- Čištění obrazu, v této metodě je použit mezikrok, který má sjednotit nejednotný jas a nízký kontrast získané duhovky. Pracuje na principu odečtení průměrného jasu pozadí pro malé bloky snímku (32x32 pixelů).
- Pro extrakci příznaků konstruuje autor množinu jednorozměrných signálů založených na vlnkové transformaci.
- Pro porovnání příznakových vektorů je použita Hammingova vzdálenost.

[4]

4.10 **Hodnocení biometrických systémů**

Na celý proces biometrické identifikace působí mnoho faktorů, které ovlivňují průběh a vyhodnocení systému. Biometrické systémy tedy nedosahují absolutní spolehlivosti – nejsou bezchybné. Výsledek může být ovlivněn každým detekce od samotné akvizice snímku až po finální rozhodování na základě srovnání míry podobnosti s nastaveným prahem. Systém pak rozhodne správně nebo chybně. Existují čtyři možné výstupy:

- Správné přijetí (True Accept)
- Správné odmítnutí (True Reject)
- Chybné přijetí (False Accept)
- Chybné odmítnutí (False Reject)

Dále budou stručně rozebrány chybové stavy, ze kterých byly odvozeny chybové míry důležité pro hodnocení biometrických systémů. [9]

- **Míra chybného přijetí** – FAR (False Accept Rate) udává pravděpodobnost biometrického systému, že dva odlišné biometrické vzory klasifikuje jako shodné. Touto chybou je např. povolen přístup neoprávněné osobě. FAR lze matematicky vyjádřit vztahem:


$$FAR = \frac{FP}{TN + FP} * 100\%, \quad (21)$$

kde FP jsou falešně pozitivní přijetí, TN pravdivě negativní přijetí. Součet ve jmenovateli tedy určuje celkový počet porovnání rozdílných vzorů duhovky. Výsledná hodnota FAR je pak vyjádřena v procentech. [9]

- **Míra chybného odmítnutí** – FRR (False Reject Rate) je definována jako pravděpodobnost biometrického systému, na základě které klasifikuje dva biometrické kódy od téže osoby jako odlišné. Tato chyba způsobuje např. odmítnutí přístupu oprávněné osoby. FRR lze vyjádřit následovně:

$$FRR = \frac{FN}{FN + TP} * 100\% \quad (22)$$

kde FN vyjadřuje negativní odmítnutí, TP pravdivě pozitivní a součet ve jmenovateli značí celkový počet porovnání vzorů duhovky jedné a téže osoby. [9]



Graf 1 Chyby FAR vs. FRR [21]

- **Míra chybné shody** – FMR (False Match Rate) udává podíl chybně přijatých vzorů duhovek osob. Míra chybné neshody je dána vztahem:

$$FMR(T) = \int_T^1 p(s|H_1)ds \quad (23)$$


kde T je práh rozhodování, p je pravděpodobnostní hustota, s je skóre porovnávání a H_1 (výrok rozdílné) označuje, že vzor a šablona náleží odlišným osobám. FMR se od FAR odlišuje tím, že do celkového součtu nejsou zahrnuty neúspěšné pokusy provedené před samotným porovnáním. [9]

- **Míra chybné neshody** – FNMR (False Non-Match Rate) označuje podíl chybně neakceptovaných osob. Výpočet FNMR je definován vztahem:

$$FNMR(T) = \int_0^T p(s|H_0)ds \quad (24)$$

kde T je práh rozhodování, p je pravděpodobnostní hustota, s je skóre porovnání a H_0 (výrok shoda) značí, že vzor a šablona náleží stejné osobě. Na rozdíl od FRR míra chybné neshody v celkovém součtu nezahrnuje neúspěšné pokusy provedené před samotným porovnáním. [9]

- **Míra vyrovnaní chyb** – EER (Equal Error Rate) je definována podmínkou rovnosti $FMR(T)=FNMR(T)$. Jelikož grafem FMR a FNMR jsou diskrétní křivky, nelze EER přesně vyjádřit. Nastavením prahu T na hodnotu EER se zaručí stejný počet chybně akceptovaných i chybně odmítnutých. K pojmu EER se pojí charakteristika ZeroFMR a ZeroFNMR. ZeroFMR značí dolní hranici FNMR. V tomto bodě je FMR rovna nule. Analogicky ZeroFNMR je dolní hranicí FMR a v tomto bodu je FNMR rovna nule. Pro názornost jsou uvedené pojmy znázorněny níže. [9]

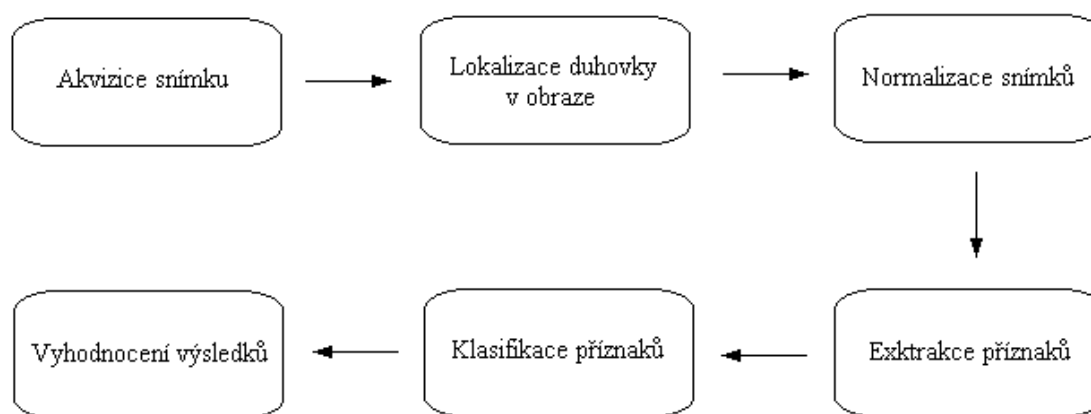


Obrázek 2 Závislost EER, ZeroFMR a ZeroFNMR [21]

- **Míra neschopnosti nasnímat** – FTA (Failure To Acquire) je podíl počtu chybných nasnímáních ke všem pokusům. Přestože je přítomna osoba k identifikaci, záznam je odmítnut. Pomocí FTA můžeme hodnotit kvalitu použitého senzoru. S rostoucí hodnotou FTA je senzor méně vhodný pro daný biometrický systém, FTA má spojitost s výše zmíněnými mírami. Vyšší hodnota FTA zvyšuje FRR a na druhou stranu snižuje FAR. [9]
- **Míra neschopnosti zaregistrovat** – FTE (Failure To Enroll) udává procentuální podíl populace, který se systém neumí naučit. FTE se dá použít jako údaj ohodnocující schopnost algoritmu pracovat s nekvalitními biometrickými příznaky. S rostoucí hodnotou FTE se zvyšuje také FRR a FAR se analogicky snižuje. [9]
- **Míra neschopnosti porovnat** – FTM (failure To Match) udává procentuální podíl biometrických charakteristik, které nebylo možné srovnat se šablonou či jakkoliv jinak zpracovat po kroku zaregistrování. FTM je ukazatelem neschopnosti systému provést rozhodnutí. [9]

5 IMPLEMENTOVANÁ METODA DETEKCE A ZPRACOVÁNÍ SNÍMKŮ DUHOVKY

Tato kapitola se zabývá návrhu metody detekce duhovky a zpracování snímků za účelem identifikace osob. Na základě prostudované literatury a publikovaných metod věnovaných biometrii oka byl navržen postup zpracování snímků duhovky, který je znázorněn na obrázku níže.



Obrázek 3 Diagram biometrické metody

Nalezení duhovky v sejmutém obraze je jeden z nejdůležitějších kroků biometrického systému. Jestliže je duhovka lokalizována v pořízeném obraze špatně či pouze částečně špatně, velkou měrou takto provedený proces ovlivní následující kroky zpracování. Je tedy velmi důležité správně a kvalitně snímky pořizovat.

5.1 Akvizice snímků

Jak je uvedeno výše, pro kvalitní akvizici je nutné použít dostatečně technicky vybavené zařízení, které umožňuje hodnotně sejmut duhovku oka. Jelikož je duhovka relativně malým orgánem a objektem, nestačí použít běžnou webkameru nebo obyčejný kompaktní fotoaparát. Přihlédneme-li už jen na fakt, že biometrický systém rozhoduje např. o verifikaci oprávněných osob u přístupu do zabezpečených prostor, přihlášení uživatele pod jeho účtem s osobními údaji nebo identifikaci pachatele při zločinu, měly by výsledky vystupující ze systému být co nejpřesnější. Výsledná chyba by měla být minimální.


Pro tyto účely byla použita databáze CASIA, která je veřejně přístupná a velmi často používaná pro analýzu jednotlivých biometrických metod. V sekci pro identifikaci podle oční duhovky se vyskytuje více databází s velkým množstvím snímků. Pro tuto práci byla zvolena

databáze CASIA-Iris-V4. Jde o nejnovější verzi snímků duhovky z původních verzí CASIA-Iris-V1 až CASIA-Iris-V3 pořizovaných od roku 2002. Celá databáze se skládá z celkem šesti oddílů a obsahuje 54 601 fotografií. Pořízené snímky jsou šedotónové v osmibitové hloubce ve formátu JPEG. Akvizice snímků byla pořízena v oblasti blízkého infračerveného světla (NIR) s vlnovou délkou 700 – 900 nm. Pro ověření kvality vytvořeného softwaru byla zvolena sekce snímků CASIA-Iris-Interval.

Oddíl CASIA-Iris-Interval byl vybrán, jelikož provedená akvizice se nejvíce blížila pořizování snímků u nabíjecích stojanů. Tato databáze se vyznačuje čistou texturou duhovky díky pořizování snímků v oblasti blízké infračerveného světla zařízením s kruhovým NIR zářičem s vhodným světelným tokem pro zobrazování duhovky. Díky akvizici snímků v oblasti blízké infračervenému záření je textura duhovky jasně viditelná a nedochází k jejímu zkreslení.

	CASIA-Iris-Interval
Typ senzoru	CASIA close-up kamera
Počet snímání	2 snímání pro většinu snímků
Počet subjektů	249
Počet tříd	395
Počet snímků	2 639
Rozlišení	320 x 280
Příznaky	Čistá textura duhovky

Tabulka 9 Parametry databáze CASIA-Iris-Interval



Obrázek 4 Náhled snímků z databáze CASIA-Iris-Interval

5.2 Lokalizace duhovky v obraze

Nejen akvizice snímků má velký vliv na korektní výsledek na výstupu biometrického systému. Detekuje-li systém duhovku ve snímku na špatné pozici, následující kroky normalizace duhovky a finální kroky porovnávání logicky neproběhnou hladce a výstupem bude výsledek s obrovskou chybou. Je proto nutné navrhnout segmentační metodu dostatečně robustní, aby systém v této fázi zpracování neměl problémy.

Pro detekci vnějšího okraje duhovky a vnitřního ohraničení duhovky – hranice zornice – byla vybrána metoda Houghova transformace. Tato metoda byla zpracována v grafickém uživatelském prostředí programu MATLAB a ověřena na snímcích z databáze CASIA, která je pro tyto účely vytvořena a celosvětově rozšířena.

Abychom mohli přistoupit k vlastnímu hledání kružnic pomocí Houghovy transformace, pořízený snímek se musí předupravit pomocí vhodné segmentace obrazu.

5.2.1 Segmentace obrazu pro nalezení vnitřní hranice duhovky

Segmentační metoda pro nalezení zornice je jednodušší než následný krok – segmentace za účelem lokalizace vnější hranice duhovky. Program MATLAB jako takový načítá všechny objekty jako matice o rozměrech $m \times n \times h$. Načtený obraz si tedy můžeme představit jako matici o rozměrech $320 \times 280 \times (\text{hodnota úrovně šedi})$. Jelikož se ale jedná o velmi rozměrnou matici a MATLAB pracuje téměř ve všech svých implementovaných funkcích s datovou proměnnou typu double, je zde nutnost obraz zjednodušit z důvodu redundance dat, kterých je v pořízeném obrazu mnoho a pro následné zpracování by software vyžadoval velký výkon a dostatek času. Což ale není přípustné pro účely identifikace a verifikace uživatele, kdy je jeden z pozorovaných parametrů čas potřebný k výpočtu zpracovávaných algoritmů, nehledě na to, že by uživatel čekal na přihlášení do systému dobu neúměrně dlouhou.

První fází je tedy převod obrazu z datové proměnné typu uint8 na datovou proměnnou typu double. Datová proměnná typu uint8 znamená unsigned integer s 8 bitovou hloubkou – tedy třetí rozměr matice je celé číslo s rozmezím hodnot 0 – 255. Převod na datovou proměnnou typu double, se změní třetí rozměr na číslo s desetinnou čárkou v rozmezí 0 – 1 v závislosti na odstínu šedi daného pixelu. Následuje další redukce dat na černobílý obraz za účelem nalezení hran v obraze, odkud se snáze detekují hrany v obraze.

Na takto upravený obraz se aplikuje hranová detekce. Hranových operátorů existuje více každý vhodný pro jiné účely. Z jednotlivých experimentů se nejvíce osvědčily Sobelův hranový operátor a Cannyho operátor. Po provedení srovnání hranových detektorů na větším množství vzorku se nejvíce jevil vhodný Cannyho detektor.

Vstupem do Cannyho hranového detektoru je 2D obraz (černobílý obraz) a parametry hranového detektoru – prahová hodnota a parametr sigma. Prahová hodnota udává senzitivitu

operátoru ve smyslu, je-li hodnota nalezené hrany menší než prahová, operátor tuto hranu zanedbává a jako hranu ji nevykreslí. Parametr sigma je skalární hodnota představující směrodatnou odchylku Gaussova filtru určující rozměr filtru. Hodnoty prahu a senzitivity sigma jsou voleny na základě experimentálních pokusů na větším počtu vzorků pořízených fotek. Cannyho hranový detektor je implementovaná funkce MATLABu volaná příkazem

$$edge(, vstupní_obraz', prahová\ hodnota, sigma)$$

Výstupem je obraz s jakousi „změtí čar“, které je nutno spojit funkcí *imdilute()*, díky čemuž se nalezené hrany spojí v jednotlivé objekty a detekování geometrických útvarů je pro výpočet méně náročnější. Takto upravený obraz je dále posílán do detekce kružnic v obraze za účelem nalezení hranice duhovky.

5.2.2 Segmentace obrazu za účelem nalezení vnější hranice duhovky

Stejně jako v předchozím kroku postupu segmentační metody je potřeba obraz pro nalezení vhodných hran a následné lokalizace okraje duhovky předupravit. Vysegmentovat z něj jen ty hrany, které jsou pro nás důležité. Záměrně se segmentační metody dělí na dvě – pro nalezení vnitřního a vnějšího okraje duhovky. Vnitřní okraj duhovky se lokalizuje jednodušeji. Účelem je lokalizovat v obraze zornici oka, což je velmi tmavý objekt v porovnání s okolím. Na této hranici je tedy možné pozorovat větší jasové skoky (jasové gradienty). Naopak při detekci vnějších hran je zde problém se světlejším okolím – oční bělma. Je tedy nutností aplikovat na snímek jasové transformace za účelem zvýšením rozdílu jasového přechodu mezi hranicí duhovky a bělma oka.

V první fázi je využito jasová úprava pomocí ekvalizace jasu funkcí *histeq(x)*. Následně je pak aplikována metoda prahování obrazu kvůli větším odstupům hledaného objektu od pozadí. Toto je provedeno pomocí implementované funkce *graythresh*, jenž využívá tzv. Otsu metodu. Tato metoda se na obraz „dívá“ jako na dvě skupiny bodů s různým rozsahem hodnot intenzity. Avšak tyto rozsahy intenzit se obvykle překrývají. Snahou metody je minimalizovat chybnou identifikaci pixelu pozadí jako popředí a naopak. Metoda se tedy snaží dosáhnout optimálního prahu tím, že snižuje společný rozptyl obou skupin bodů následným algoritmem

$$\sigma_b^2(T) = n_b(T)n_0(T)[\mu_b(T) - \mu_0(T)]^2 \quad (25)$$

$$n_b(T) = \sum_{i=0}^{T-1} p(i) \quad (26)$$

$$n_0(T) = \sum_{i=T}^{N-1} p(i) \quad (27)$$

$$\mu_b(T) = \sum_{i=0}^{T-1} \frac{ip(i)}{n_b(t)} \quad (28)$$

$$\mu_0(T) = \sum_{i=T}^{N-1} \frac{ip(i)}{n_0(t)} \quad (29)$$

Kde $\sigma_b^2(T)$ je vzájemný rozptyl obou skupin bodů, T je aktuálně zkoumaná hodnota prahu a $[0, N - 1]$ je rozsah úrovní intenzit, $p(i)$ je počet pixelů o dané intenzitě. Algoritmus pro každou uvažovanou hladinu prahu rozděluje pixely do skupin podle hodnoty prahu, spočte průměr v každé skupině, rozdíl průměrů exponuje na druhou a vynásobí počet pixelu v každé skupině. Hledaný práh je takový, který má maximální hodnotu $\sigma_b^2(T)$. Tento algoritmus je zakomponován v implementované funkci

$$[level\ EM] = graythresh(vstupní_obraz)$$

Funkce vypočítává globální práh, který může být použit pro konverzi obrazu intenzity na binární obraz. Vybere práh, aby se minimalizoval vnitrodruhový rozptyl černých a bílých pixelů- Vicedimenzionální pole jsou pak automaticky převedeny na 2-D pole pomocí přetvarování pole. Funkce ignoruje jakoukoliv nenulovou imaginární část vstupního obrazu. Tato metoda vrací jako proměnnou *level* normalizovanou hodnotu intenzity, která leží v intervalu $[0, 1]$. Jako druhý výstupní argument *EM* pak vrací tzv. *metrickou účinnost*, což je hodnota v rozsahu $[0, 1]$, která ukazuje účinnost prahování vstupního obrazu. Spodní mez je dosažitelná pouze obrazy, které mají jednu úroveň šedi a horní mez je dosažitelná pouze s dvouhodnotovými obrazy.


Výstupní argument *level* z prahovací funkce je následně využit v již výše zmíněné funkci *im2bw*, která převádí šedotónový obraz na obraz binární, a jednotlivým pixelům přiřazuje hodnoty podle výstupní proměnné *level*.

5.2.3 Houghova transformace

Po jednotlivých segmentačních metodách – hranových detekcí – je obraz předupraven pro detekci duhovky. Cílem Houghovy transformace je najít podmnožinu bodů z originálního šedotónového snímku $I(r,c)^5$, která nejvíce odpovídá hledanému primitivu, v našem případě parametrům Houghovy transformace. Houghova transformace je definována jako mapování bodů z původního obrazu do tzv. akumulátoru A a hledaná kružnice je pak popsána rovnicí:

$$(x - x_0)^2 + (y - y_0)^2 = r^2 \quad (30)$$

Kde x a y jsou souřadnice bodu na kružnici, x_0 a y_0 jsou souřadnice středu kružnice r je poloměr kružnice. Každý hraniční bod v akumulátoru je vyjádřen sadou kružnic zobrazených na obr. 7.

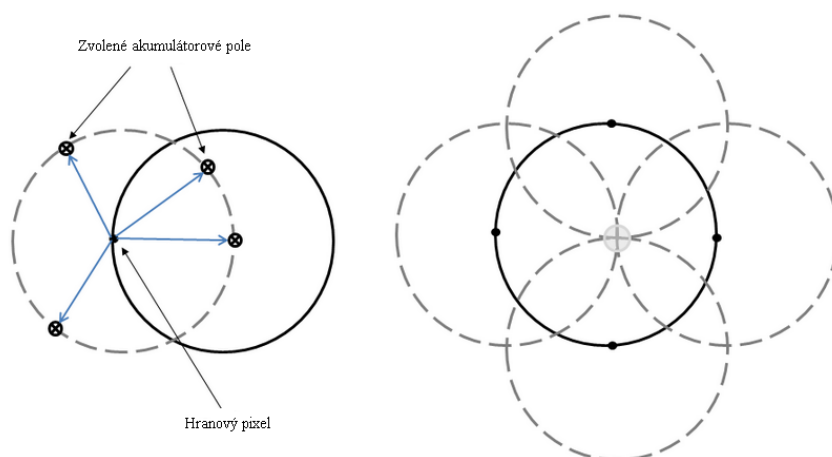


Obrázek 5 Prostor akumulátoru [22]

Tyto kružnice jsou pak dány zvoleným rozmezím poloměrů a jejich středy leží na souřadnicích hraničních bodů. Na výše uvedeném obrázku jsou kružnice dány třemi hraničními body. Každý hraniční bod definuje kružnice pro jinou hodnotu poloměru. Akumulátor $A(r, c, R)^6$ je tedy trojrozměrná matice daná třemi hledanými parametry kružnice x_0 , y_0 a r . Výsledné parametry kružnice z původního snímku jsou získány jako maximální hodnota zaplněného akumulátoru.

V prostředí MATLAB je pro využití Houghovy transformace implementovaná funkce *imfindcircles*, která obsahuje následující algoritmus. Zmíněná funkce využívá k lokalizování kružnic v obraze tzv. Kruhovou Houghovu transformaci. Tento přístup se používá vzhledem k jeho odolnosti a přítomnosti šumu, okluze a různého osvětlení. Kruhová Houghova transformace obecně využívá tři základní kroky:

- 1) Pixely s vysokým gradientem v popředí jsou označeny jako vhodné pixely pro ukládání do pole akumulátoru. Tyto vhodné pixely pak volí vzory kolem nich, což následně tvoří plnou kružnici kolem daného poloměru. Viz obr.8. Obrázek také znázorňuje vhodně zvolené pixely ležící na hledané kružnici (plnou čarou) a pixely vhodně zvolené pro pomocné kružnice (čárkovanou čarou).



Obrázek 6 Ukázka nalezení hledané kružnice pomocí volby pixelů [22]

- 2) Znaky vhodných pixelů, které patří do obrazu kruhu, mají tendenci se hromadit v zásobníku akumulátoru pole, což odpovídá středu hledaného kruhu. Díky tomu jsou středy požadovaného kruhu odhadovány pomocí detekce píku v akumulátoru pole – překrývání ve středu skutečného kruhu.
- 3) Je-li stejný akumulátor pole použit pro více než jednu hodnotu poloměru, jak se běžně provádí v Kruhové Houghově transformaci algoritmů, poloměry detekovaných kruhů musí být odhadnuty jako samostatný krok.

Funkce *imfindcircles* pak přesně využívá dvě metody, které se liší ve způsobu vypočtení poloměru kružnice.

- Poloměry jsou odhadovány výslovně pomocí odhadu středu kruhů spolu s obrazovou informací. Tato technika je založena na výpočtu radiálního histogramu.
- Komplexní hodnoty v akumulátoru pole spolu s informacemi o poloměru jsou zakódované ve fázi položek pole. Hranové pixely obsahují informace nejen o možných místech, kde by se mohl nacházet střed kruhu, ale i o poloměru kruhu spojené s centrální polohou. Na rozdíl prvního způsobu, kde se poloměr odhaduje pomocí radiálního histogramu, lze při kódování pomocí fáze poloměr odhadnout pouze dekodováním fázové informace z předpokládané středové polohy v akumulátoru pole.

Zmíněná funkce se v MATLABu volá příkazem

```
[souřadnice_středu, poloměr]=imfindcircles(obraz,[min_poloměr max_poloměr], 'Sensitivity',  
zvolené_citlivost)
```

tedy *imfindcircles* nachází v obraze požadovaný kruh s očekávaným poloměrem v rozmezí *min_poloměr* a *max_poloměr* s nastavenou citlivostí (*Sensitivity*) a ukládá do vektoru souřadnice středu a poloměr detekované kružnice. Vstupem do funkce je obraz v našem případě binární po hranové konverzi, již výše zmíněný rozsah poloměrů definovaný vektorem s minimální a maximální hodnotou, Parametr *Sensitivity* (citlivost) je volen kladnou skalární hodnotou v intervalu [0;1]. Se zvýšením citlivosti je zvýšeno riziko detekování falešných kruhů.

Po řadě vykonaných experimentálních pokusech se osvědčila volba citlivosti na hladinu 0.89, kdy chybovost byla nejmenší a vyvážená s korektní detekcí v obraze. Pro nalezení vnitřního okraje duhovky se ukázalo jako nejvhodnější použít očekávané rozmezí hodnot poloměru kružnice v intervalu [30; 65], pro detekování vnějšího okraje duhovky pak [100; 130]

Jednotlivé kružnice jsou pak dále vykresleny do původního obrazu pomocí příkazu *viscircles* příkazem

```
viscircles=(souradnice_středu, poloměr, 'EdgeColor', 'r', 'DrawBackgroundCircle', 'false')
```

kde vstupní parametry jsou *souřadnice_středu* kružnice a *poloměr* kružnice. Zbylé dva parametry slouží k volbě barvy vykresleného kruhu (*EdgeColor* – *r* – červená barva) a zda se má či nemá (*true* / *false*) vykreslit kontrastní pozadí pod vykreslenou kružnici (*DrawBackgroundCircle*).

5.2.4 Extrakce duhovky pomocí binární masky

Jakmile jsou v obraze detekovány okraje duhovky, můžeme přistoupit k finálnímu kroku detekce duhovky v obraze a to k extrakci duhovky z originálního obrazu. K tomuto kroku je využita metoda překrytí originálního obrazu binární maskou. Známe-li parametry kružnic ohraničujících hledanou duhovku, můžeme vytvořit tzv. binární masku takovou, že když ní překryjeme původní obraz, vzniknou dvě oblasti – pozadí a oblast duhovky.

Aby se vyextrahovala pouze duhovka, což je geometrický útvar mezikružní, je potřeba finální masku složit z více dílčích masek. K těmto účelům byla vytvořena jedna maska taková, že všechny pixely ležící vně kružnice zvenku ohraničující duhovku nabydou hodnoty 1 (bílá/průhledná) a ostatní 0 (černá), a druhá taková, že všechny pixely ležící vně kružnice ohraničující zornici nabydou hodnoty 0 (černá) a ostatní 1 (bílá/průhledná). Součtem těchto masek vznikne tak matice, kde pixely ležící v námi hledané oblasti duhovky nabývají hodnot 2, ostatní 1. Dále je tedy třeba těmto pixelům přiřadit hodnoty takové, aby oblast byla průhledná,

tedy hodnoty 0. Tento postup je realizován *for* cyklem, který prochází maticí sloupec po sloupci a v každém sloupci projde všechny prvky resp. pixely a zjišťuje, jakou nabývají hodnotu. Všem pixelům, které nabývají hodnoty 2, přiřadí hodnotu 1, ostatním pixelům definuje hodnotu 0. Každý takto pozměněný pixel ukládá do předem vytvořené matice. Jelikož je načtený obraz v systému MATLAB načtený jako matice, pro překrytí finální masky s originálním obrazem pak stačí pouze vynásobit všechny prvky matice originálního obrazu s prvky matice finální masky, tím se z originálního obrazu oddělí pixely ležící v oblasti duhovky od pozadí – pro nás nedůležitá data viz obr.10.

```
[xm1,ym1]=meshgrid(-(centers1(:,1)-1):(sirka-centers1(:,1)),-(centers1(:,2)-1):(vyska-centers1(:,2))));
```

```
c_mask=((xm1.^2+ym1.^2)<=radii1^2);
```

```
[xm,ym]=meshgrid(-(centers(:,1)-1):(sirka-centers(:,1)),-(centers(:,2)-1):(vyska-centers(:,2))));
```

```
c_mask2=((xm.^2+ym.^2)>=radii^2);
```

```
maska=c_mask+c_mask2;
```

```
maska=maska(:, :, 1);
```

```
for i=1:size(maska,1)
```

```
    for j=1:size(maska,2)
```

```
        pixel=maska(i,j);
```

```
        if pixel==2
```

```
            new_pixel=1;
```

```
        else
```

```
            new_pixel=0;
```

```
        end
```


```
        maska_final(i,j)=new_pixel;
```

```
    end
```


```
end
```

```
prekryty_obraz=originalni.*mask_final;
```


Algoritmus pro tvorbu binární masky




Obrázek 7 Postup tvorby binární masky



Obrázek 8 Postup aplikace binární masky na originální obraz



Obrázek 9 Ukázka hranové detekce vnitřních okrajů duhovky (vlevo) a vnějších okrajů (vpravo)




Obrázek 10 Vykreslené kružnice (vlevo), vyfiltrovaná duhovka (vpravo)

5.3 Normalizace duhovky

Jakmile byla oddělena duhovka od pozadí v předchozím kroku, mohlo se přistoupit k další fázi – normalizaci duhovky. Normalizace duhovky byla provedena polarizací souřadnic z kartézské soustavy souřadnic do soustavy polární. Tímto se oblast mezikruží (duhovky) přetne v poloměru a „roztáhne“ na pásek.

5.3.1 Polarizace souřadnic

Nejprve se musela zvolit pouze oblast duhovky, což bylo provedeno implementovanou funkcí *imcrop*. Dále se pak pomocí rovnic (13) uvedených výše vypočetly jednotlivé polární souřadnice. Zvolil se rámeček, do kterého se převedené polární souřadnice vykreslí jako „rozevřená“ duhovka. Velikost rámečku byla zvolena na konstantní šířku 128x360, kde 360 je délka pásku a 128 je šířka pásku. Velikost byla volena záměrně tak, že délka 360 odpovídá úhlu kruhu 360°, šířka 128 pak byla volena experimentálně z důvodu přehlednosti pásku, aby nebyly vizuálně zkresleny obrazové informace. Představíme-li si 360 řezů, viz názorný obr. 12, je zřetelné, že dochází k určitým ztrátám informací. Jelikož se směrem od středu mezikruží vznikají zvětšující se mezery mezi jednotlivými řezy, je tento problém vyřešen interpolační metodou nejbližšího souseda použitím funkce *TriScatteredInterp*. Vstupem do této funkce jsou předem vypočtené polární souřadnice. Konvertované souřadnice hodnot jednotlivých pixelů spolu s interpolovanými hodnotami jsou pak vykresleny do výše popsaného rámečku.



Obrázek 11 Ukázka zvětšujících se mezer mezi úhlovými řezy [21]

pasek duhovky



Obrázek 12 Normalizovaná duhovka

5.3.2 Jasové úpravy normalizované duhovky

Po normalizaci duhovky měly snímky stále nízký kontrast a mohly se vyznačovat nerovnoměrným osvětlením. Z důvodu zkvalitnění následně extrahovaných příznaků a detekce byl zařazen krok předzpracování obrazu zvyšující kontrast normalizované oblasti. Na obr. 12 jsou uvedeny jednotlivé dílčí kroky předzpracování obrazu.

Prvním krokem tohoto postupu bylo získání rozostřeného obrazu normalizovaného snímku, který měl vyšší obsah nízkofrekvenčních složek. Rozostření bylo provedeno pomocí průměrovací masky velikosti 11x11 pixelů. Aby nedocházelo k okrajovým jevům, byl normalizovaný snímek před samostatným rozostřením rozšířen o okraje. Z důvodu, že normalizovanou duhovku vzhledem k vertikálnímu směru můžeme chápat jako periodický snímek, rozšířili jsme snímek vlevo o v sloupců z pravé strany duhovky, analogicky jsme vpravo provedli rozšíření o v sloupců z levé strany duhovky. Hodnota rozšíření v je odvozena od velikosti použité masky:

$$v = \frac{m - 1}{2} \quad (31)$$

Kde m je velikost strany masky. V našem případě byla zvolena velikost $m = 11$. V horizontálním směru signál periodicitu nevykazuje, z tohoto důvodu byl normalizovaný snímek v horní a dolní části rozšířen o pět řádků nul. Po rozmazání průměrovací maskou bylo rozšíření zase odebráno, aby nízkofrekvenční snímek získal původní velikost jako normalizovaný snímek. Takto rozostřený snímek byl odečten od původního normalizovaného. Tímto krokem došlo k relativnímu snížení nízkofrekvenčních složek v normalizovaném snímku. Detailní snímek získaný po odečtení byl zpětně přičten k původnímu normalizovanému snímku, čímž jsme dosáhli zvýraznění detailů a hran v obraze, tedy zdůraznění vysokých prostorových frekvencí.



Obrázek 13 Postup zvýšení kontrastu normalizované duhovky




a)



b)



c)




d)

Obrázek 14 a) Normalizovaná duhovka, b) Rozostřený snímek, c) Vyokofrekvenční snímek, d) Snímek se zvýšeným kontrastem

5.4 Extrakce příznaků

Jakmile byly na normalizované duhovce provedeny jasové úpravy, bylo možné přistoupit k fázi extrakce důležitých příznaků. Myšlenkou extrakce je příprava pro následné porovnávání, resp. vytváření šablony ukládané do databáze sloužící jako identifikační údaj daného uživatele. Po polarizaci souřadnic a následném „roztáhnutí“ mezikruží na pásek vznikly vlivem interpolační metody artefakty v upravovaném obraze. Tyto artefakty přidávaly do obrazu falešné informace, které bylo nutné odstranit. Stejně tak se objevovaly oční víčka díky nedostatečnému rozevření oka během akvizice snímku.

Jak bude rozebráno dále, porovnávací algoritmus pracuje na porovnávání vzájemné korelace pořízeného snímku se šablonami v databázi. Vytvořenou šablonu – zpracovaný pásek duhovky – si můžeme představit jako matici, jejíž každý řádek představuje 1D signál popisující změny intenzity. Obraz vstupující do fáze extrakce nese rozměry 128x360 pixelů. Z literatury je možno vyčíst, že nejvíce důležitých příznakových vektorů je koncentrováno v oblasti od vnitřního okraje směrem k vnějšímu okraji. Z této oblasti zabírající 80% celé duhovky bylo extrahováno celkem 70 1D signálů intenzit normalizované duhovky. První signál byl extrahován ze třetího řádku upraveného normalizovaného snímku ve snaze zamezit možného výběru signálu v místě se zachycenou zornicí. Obdobně byly vypuštěny 1D signály s možným ovlivněním očních víček nacházejících se v horní oblasti normalizované duhovky. Na obr. 17 můžeme vidět názornou ukázkou 1D signálů a jejich polohu v normalizovaném snímku.



Obrázek 15 Normalizovaná duhovka s vyznačenými signály (nahore), vykreslené vyznačené 1D signály (pod normaliz. duhovkou)

5.5 Ukládání dat do databáze

Pro uložení dat byl vytvořen datový model, který je podobný standardní databázi. Databáze byla vytvořena prázdná, přichystána pro následné plnění osobami. Pro tento účel posloužila online přístupná databáze CASIA popsaná výše, jejímž snímkům byla přiřazena jména.







Databáze je struktura, což je datové pole s jednotlivými názvy subpolí, které mohou obsahovat data různých datových proměnných o různých velikostech. Pole struktury je datový typ, který seskupuje související data pomocí tzv. datových kontejnerů zvaných pole. Každé takové pole může obsahovat jakýkoliv typ dat. Přístup k datům ve struktuře se provádí pomocí příkazu *názevStruktury.názevPole*. Tvorba databáze byla provedena následujícím sledem příkazů:

```
templates.name='';  
templates.template=[];  
templates.photo=[];  
templates.eye='';  
save(,templates.mat')
```

Uvedená struktura je jednořádkový vektor, jehož každý prvek obsahuje jedinečné údaje o daném uživateli. Kde *templates.name=''* znamená vytvoření pole s názvem Name a uvozovky definují datovou proměnnou typu String, *templates.template=[]* vytváří prázdnou matici pro uložení vytvořené šablony typu double, *templates.photo=[]* zapíše do definované struktury pole s názvem photo očekávané datové proměnné typu double a *templates.eye=''* stejně jako u tvorby pole pro jméno vytvoří pole pro zadání levého či pravého oka o datové proměnné typu String. Každému uživateli databáze je přiřazeno jeho ID číslo v databázi – pořadí profilu v databázi (1,2,3,...), jméno, které při zaregistrování zadá, původní fotografie pořízená při prvním sejmutím a uložení profilu, jeho vytvořená šablona z pořízeného snímku při akvizici a údaj, zda se jedná o levé či pravé oko.



Obrázek 16 Diagram vytvořené databáze

	templates	<1x92 struct>
	templates(1, 49)	<1x1 struct>
	name	'Patrik'
	template	<70x360 double>
	photo	<280x320 double>
	eye	'L'

Obrázek 17 Uživatelský profil v databázi

Na obr. 19 je možno vidět názornou ukázkou, jak vytvořená databáze vypadá, resp. jejího člena. Z uvedené databáze o 92 členech (*templates* <1x92 struct>) je náhodně zvolen 49. člen (*templates(1,49)* <1x1 struct>), což je vidno z dané pozice elementu v řadě vektoru. Jeho jméno je Patrik (*name* ,Patrik'), je zde uvedena jak vytvořená šablona (*template* <70x360 double>), tak jeho fotografie při zaregistrování do systému (*photo* <280x320 double>), a údaj o jaké oko se jedná – v tomto případě se jde o levé oko (*eye* ,L').

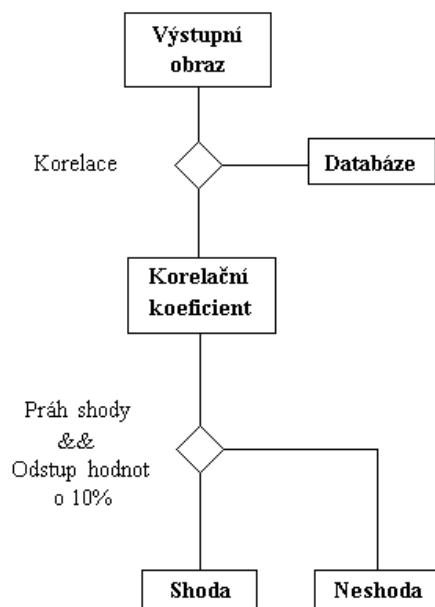
5.6 Porovnávání příznaků

Pro porovnávání získaných příznakových vektorů s biometrickými daty uloženými v databázi byla zvolena metoda porovnávání korelačních koeficientů pro její univerzálnost a větší odolnost vůči posunu vektorů způsobeným natočením duhovky. Použití jednodušších metod jako je Hammingova vzdálenost by komplikovalo a zpomalovalo výpočet, jak již bylo zmíněno v úvodních kapitolách.

Podle definice viz kapitola 4, vypočteme korelační koeficient pro porovnávaný příznakový vektor a každý vektor z databáze, přičemž minimalizujeme tento korelační koeficient vzhledem k nejmenšímu možnému, který je uložen v databázi, abychom jej nemuseli počítat při každém průchodu. Pro každý záznam v databázi toto skóre normalizujeme a dále jej používáme jako pravděpodobnostní hodnotu shody.

Ze získané množiny pravděpodobnostních hodnot shody vybereme maximum a pokud splňuje následující podmínky, je uživateli oznámena shoda. Podmínky (určeny viz následující kapitola) pro úspěšné přijetí obrazu a potvrzení shody jsou následující:

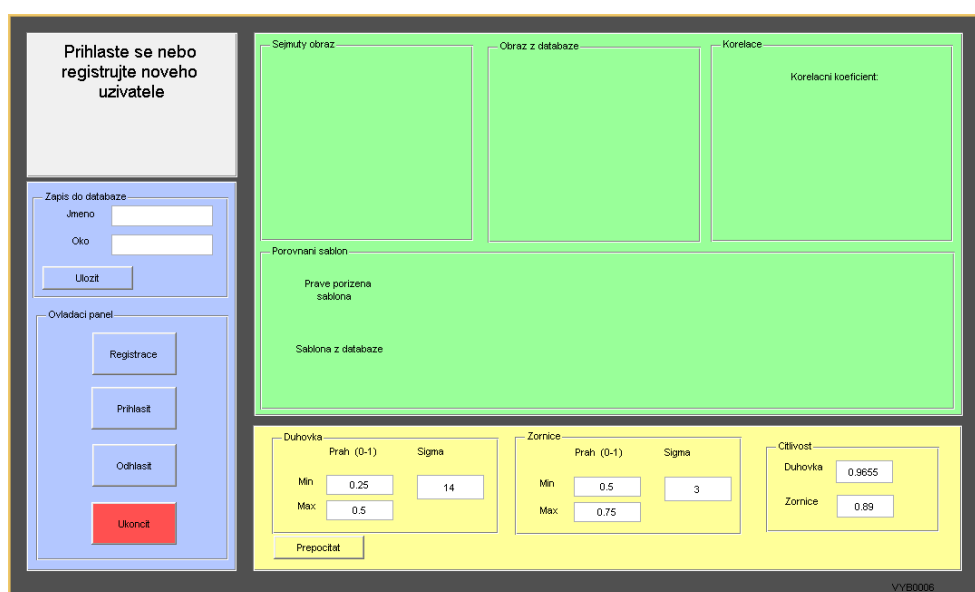
- Korelační koeficient je větší než 0,2
- Odstup od dalších hodnot minimálně 10%



Obrázek 18 Diagram rozhodovacího algoritmu

5.7 Uživatelské rozhraní

Pro přehlednost a celistvost práce bylo vytvořeno grafické uživatelské prostředí (GUI) v programu MATLAB (viz obr. 21). Toto GUI využívá vytvořených funkcí, které volá a pomocí níž provádí jednotlivé výpočty a úkony. Zobrazuje v něm veškeré snímky, jak pořízené tak programem zpracované, průběžné výpočty využívané v rozhodovacím algoritmu, ale také průvodní instrukce pro uživatele.



Obrázek 19 Grafické uživatelské rozhraní

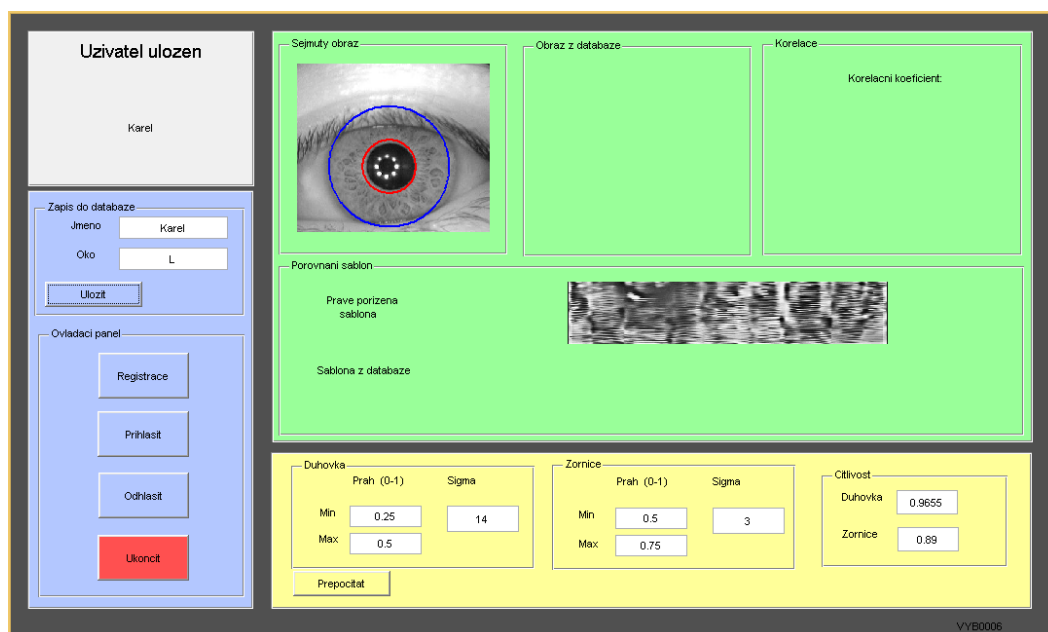
Jelikož by měl být program v praxi plně automatizován s minimálními požadavky na uživatele, vše probíhá bez větších zásahů a akcí dané osoby. Pro přehlednost je GUI barevně rozděleno – šedý sektor vpravo nahoře slouží k instrukcím mířeným na uživatele, modrý sektor pod ním uživatel využívá k ovládání celého programu (je zde umístěný ovládací panel s příslušnými ovládacími prvky), v zeleného sektoru jsou zobrazovány průvodní snímky společně se šablonami a poslední žlutý sektor je doplňkový sloužící pro ladění průběžného zpracování jako např. citlivost Sigma při detekci hran, citlivost hledání kružnic v obraze atd.

Program se spouští ze systémové složky, ve které jsou nakopírovány všechny potřebné soubory, skriptem *„Nacteni.m“*. Po spuštění se objeví dialogové okno s vlastním grafickým prostředím programu. Dále má uživatel na výběr, zda se chce do systému zaregistrovat nebo přihlásit. Toto provede zvolením jednoho z ovládacích prvků v modré sekci – *Registrace* nebo *Přihlášení*. Každý ovládací prvek vykoná akci, kterou volá požadovanou funkci. Pro potřeby registrace je volán funkční skript *„detekce.m“*, který postupně plní jednotlivé kroky postupu pro detekci a zpracování pořízeného snímku. Přihlášení uživatele je pak realizováno ovládacím prvkem *„Přihlásit“*, jenž volá funkci *„porovnavani.m“*. Průchod postupem je pak obdobný jako u registrace uživatele.

5.7.1 Registrace uživatele

Po spuštění programu se v informačním sektoru objeví text *„Přihlaste se nebo vytvořte nového uživatele“*. Není-li uživatel zapsaný v databázi, je potřeba, aby se pro další úkony do systému zaregistroval. Toto uživatel provede následným sledem jednotlivých jednoduchých úkonů. V ovládacím sektoru uživatel zvolí možnost *„Registrace“*, kde se v tomto případě otevře dialogové okno s možností výběru předem pořízené fotografie (avšak do budoucna se počítá s přímým propojením programu s akvizičním zařízením) a v informačním sektoru se objeví text *„Vyberte fotku“*. Není-li fotografie vybrána, vyskočí chybové dialogové okno s informací, aby uživatel vybral fotografii.

Jakmile uživatel vybere svou fotografii, v šedém sektoru se objeví informace *„Vyčkejte, než proběhne proces zpracování obrazu“*. Proběhne-li zpracování obrazu v pořádku, v informačním okně se zobrazí text *„Hotovo, zadejte jméno a o jaké oko jde“*, na pořízeném snímku se vykreslí kružnice ohraničující z obou stran nalezenou duhovku ve snímku a dále se v zelené sekci v poli *„Porovnání šablon – Právě pořízená šablona“* také vykreslí vytvořená šablona duhovky, připravená k uložení do databáze pod příslušným jménem uživatele. Dokončení kroku registrace uživatel provede opět v modré sekci nad ovládacími prvky, kam do pole *„Zápis do databáze“* zadá podle informačního panelu své jméno a o jaké oko se jedná (levé či pravé). Po zadání svého jména a informace o typu oka uživatel zvolí ovládací prvek *„Uložit“*. V šedé informační zóně se objeví hlášení *„Uživatel uložen“* a pod ním se vypíše jméno právě uloženého uživatele. Tímto je uživatel zapsán do databáze (viz obr. 22) a pro přihlášení je třeba provést následující jednoduché kroky popsané dále.



Obrázek 20 Registrace vytvořeného uživatele

5.7.2 Přihlášení uživatele

V tomto případě se jedná o situaci, kdy je už uživatel zapsán do databáze a chce se pouze přihlásit do systému. Jak již bylo uvedeno výše, po spuštění programu se v informačním panelu objeví hlášení „Přihlaste se nebo registrujte nového uživatele“. Uživatel tedy podle informačního textu zvolí druhou možnost, a to ovládací prvek „Přihlásit“. Taký zde v této fázi uživatel vybere jednu z fotografií pořízené předem (v budoucnu se počítá s přímým propojením akvizčního zařízení se softwarem) z dialogového okna. Nevybere-li žádnou, opět se objeví chybové hlášení, že uživatel nevybral žádnou fotografii.

Zvolil-li (pořídil-li) uživatel snímek své duhovky za účelem přihlášení do systému, v informačním panelu se objeví text „Vyčkejte, než proběhne proces zpracování“. Jakmile program dokončí proces zpracování snímku, vykreslí se, obdobně jako u registračního kroku, jeho právě pořízený snímek v zeleném sektoru v poli „Sejmutý obraz“ s vyznačenou duhovkou a jeho vytvořená šablona duhovky v poli „Porovnání šablon – Právě pořízená šablona“. Následuje vlastní porovnání jednotlivých šablon v databázi s právě pořízenou.

Jsou zde dvě možnosti, jak se dále systém zachová – buď najde shodu s uživatelem uloženým v databázi a přihlásí jej, nebo nenajde žádnou shodu s již uloženými uživateli v databázi a k přihlášení nedojde. Jestliže software vyhodnotí situaci tak, že shodu s určitým uživatelem nalezne, v informačním sektoru se objeví hlášení jméno přihlášeného uživatele a oznámení „Nalezena shoda uživatele“. Dále se ve zobrazovací sekci vykreslí sejmutý obraz uživatele při jeho registraci v poli „Obraz z databáze“, šablona duhovky vytvořená při registraci v poli „Porovnávání šablon – Šablona z databáze“ a údaje o korelační analýze porovnávaných

šablon v poli ‚*Korelace*‘, resp. vykreslený graf korelačních koeficientů všech uživatelů v databázi. Graf reprezentuje odstup největší shody od ostatních vypočtených korelačních koeficientů a slouží tak jako vizuální posouzení, zda se jedná o náhodný či jednoznačný výsledek (viz obr. 23).

Vladan

Nalezena shoda uživatele

Zapis do databaze

Jmeno

Oko

Ovladaci panel

Sejmutý obraz

Obraz z databaze

Korelace

Korelační koeficient:
0.334579

Porovnání šablon

Prave porizena šablona

Šablona z databaze

Duhovka

Prah (0-1) Sigma

Min

Max

Zornice

Prah (0-1) Sigma

Min

Max

Citlivost

Duhovka

Zornice

VYB0006

Obrázek 21 Přihlášení uživatele

6 ZHODNOCENÍ VÝSLEDKŮ

Tato kapitola se zabývá zhodnocením výsledků dosažených simulováním možných reálných situací při ostrém provozu v praxi. Jsou zde uvedeny testy trvání jednotlivých úkonů a rozebrána spolehlivost jak detekce samotné duhovky v obraze, tak samotná komplexní spolehlivost vytvořeného biometrického systému.

Testy byly prováděny na osobním počítači – notebooku – s následujícími parametry, jejichž ovlivňují chod programu:

- Operační systém – Windows 8 Pro, 64bit
- Procesor – Intel Core i3 3217U, 1,8 GHz
- Operační paměť – 4 GB

6.1 Průběh experimentu

Tato kapitola popisuje strukturu prováděného experimentu pro verifikaci parametrů navrhnutého biometrického systému. Průběh experimentu se skládá ze dvou částí a to z naplnění databáze reálnými daty a následného „ostrého“ provozu.

V reálu by se o postupném naplňování databáze dalo hovořit jako o neautonomní fázi, během které by musela být přítomna jednak osoba zavedená do databáze, jednak lidský operátor – instruktor podávající pokyny pro korektní akvizici snímků. Toto je ovšem nahrazeno online databází CASIA popsanou viz výše.

Databáze byla tedy naplňována takovými daty, které by splňovaly předpoklady pro korektní akvizici popsané následovně. Počet snímků v databázi pro každého jedince se pohybuje v rozmezí od 3 – 10 fotek. Z těchto snímků byl vybrán vždy ten nejzdařilejší ve smyslu, že je duhovka oka zachycena v celém rozsahu (nepokračuje mimo snímek), osa oka je co nejvíce kolmá na optiku snímače (lze orientačně určit ze soustřednosti detekovaných kružnic), pořízený snímek není více zašuměn a duhovku zakrývá co nejméně nechtěných artefaktů (oční víčka, řasy, odlesky). Dodržením těchto podmínek zvyšuje přesnost detekce duhovky a zefektivňuje následné kroky rozpoznávání jednotlivých duhovek. Z vybraného snímku byl vytvořen unikátní etalon pro každého jedince a uložen do databáze pod jeho iniciály.

Ze simulace ostrého provozu se pak získaly data, které se mohly dále zpracovat a z nich vyhodnotit o jak silný program se jedná. Simulací je myšleno výběr a následný test co nejodlišnějších snímků od originálu uloženého v databázi. Tímto je dosaženo komplexního posouzení, zda systém má nějakou vypovídající hodnotu.

6.2 Výsledky použité implementace

V této kapitole jsou uvedeny výsledky testů rychlosti a spolehlivosti implementovaného algoritmu formou tabulek a k nim odpovídajícím komentářům.

6.2.1 *Testy rychlosti*

Metoda	Průměrná doba [ms]	Odchylka [ms]
Předzpracování	330	30
Hough. transformace	330	40
Tvorba binární masky	30	10
Normalizace	510	50
Extrakce	150	20
Celkem	1 350	150

Tabulka 10 Časy potřebné pro registraci uživatele

Časy potřebné pro úpravu pořízených snímků jsou uvedeny v tabulce 10. Celý proces trvá v průměru 1,35s. Proces segmentace snímku (předzpracování, Houghova transformace a aplikace binární masky) v průměru nepřesáhl 700ms. Polarizace souřadnic spolu s jasovými úpravami normalizované duhovky (normalizace) trval v průměru 510ms a pro samotnou extrakci příznaků je potřeba v průměru 150ms. Odchylky jednotlivých metod se pohybují řádově v desítkách ms a odchylka celého procesu je pak součtem všech odchylek, což dává dohromady ± 150 ms. Časově nejnáročnější je celková segmentace snímku, u které je taky největší časová odchylka ve výpočtu. Nejkratší doba trvání je pak u extrakce příznaků.

Metoda	Průměrná doba [ms]	Odchylka [ms]
Načtení databáze	3 350	43
Korelace	3 617	17
Vlastní vyhodnocení	0 503	4
Celkem	8 820	64

Tabulka 11 Časy potřebné pro přihlášení uživatele


V tabulce 11 je uvedena průměrná doba trvání pro přihlášení spolu s odchylkami. Celkový součet doby trvání tvoří součet tří parametrů uvedených v tabulce 11 (Načtení databáze, Korelace, Vlastní porovnávání) s celkovou dobou trvání pro registraci viz tabulka 10. Čas potřebný k přihlášení osoby do systému je tedy 8,82s. Doba potřebná pro načtení databáze je 3,35s. Je to zároveň parametr, který je nejvíce proměnlivý díky tomu, že je závislý na robustnosti databáze. Platí zde přímá úměra – čím více je v databázi zapsaných osob, tím déle bude trvat, než program načte celou databázi. Podobně se odvíjí i korelace, i když změny v čase

tak markantní nejsou, což vyplynulo z více provedených testů, kdy se měnil počet osob v databázi. Odchytky výpočtů jsou opět jako v předešlém případě v řádech desítek ms, celková odchylka přihlašování do systému je 64ms.


Počet osob v databázi	Průměrná doba [s]	Odchylka [s]
Zápis do databáze (30)	2,43	0,17
Porovnávání (30)	3,92	0,03
Zápis do databáze (60)	4,56	0,16
Porovnávání (60)	6,13	0,02
Zápis do databáze (90)	7,09	0,35
Porovnávání (90)	8,82	0,06

Tabulka 12 Porovnání potřebné doby k jednotlivým úkonům v závislosti na počtu osob v databázi

Tabulka 12 udává, jak se mění doba potřebná pro uložení osoby do databáze a jak se mění doba potřebná pro porovnávání osob v databázi v závislosti na počtu osob již zapsaných v databázi. Z tabulky lze vyčíst, že obě doby (uložení, porovnání) potřebné k požadovanému úkonu jsou závislé na velikosti databáze. Při 30 lidech v databázi není doba zápisu delší než 2,6s, naopak při 90 lidech v databázi nepřekročí 7,5 vteřiny. Při vlastním porovnávání jsou časy analogické s tím rozdílem, že porovnávání je mírně časově náročnější než zápis. Závislosti jsou zobrazeny v grafu 1 a grafu 2 viz níže. Oba grafy jsou aproximovány exponenciální funkcí s určitou předpovědí hodnot. V případě zápisu uživatele do databáze jde o přibližně exponenciální závislost a stejně tak v případě závislosti pro přihlášení uživatele.



Graf 2 Závislost času potřebného pro uložení osoby do databáze s aproximací



Graf 3 Závislost času potřebného pro přihlášení uživatele s aproximací


Jak bylo uvedeno výše a z grafů 1 a 2 lze usoudit přibližně exponenciální závislost potřebného času pro uložení nebo přihlášení k počtu uživatelů zapsaných v databázi. V případě ukládání uživatele byla rovnice aproximační křivky

$$y = 0,0002x^2 + 0,051x + 0,7 \quad (32)$$


V případě přihlášení uživatel do systému byl předpis aproximační křivky dán rovnicí

$$y = 0,0003x^2 + 0,0497x + 2,19 \quad (33)$$

Z rovnic 32 a 33 lze pak provést přesnější odhad potřebného času pro uložení/přihlášení uživatele do systému s početnější databází, přesněji s 1000 uživateli, což je více jak deseti násobek testovací databáze, viz grafy 3 a 4.



Graf 4 Odhad doby pro ukládání uživatele do databáze s tisíci uživateli



Graf 5 Odhad doby potřebné pro přihlášení do systému při tisícové databázi


Z grafů uvedených výše lze pozorovat exponenciální charakter růstu času potřebného pro přihlášení/uložení do systému. Tento poznatek nám udává, jak bychom měli postupovat při tvorbě potřebného HW při realizaci systému. Na testované HW sestavě, popsané výše, se při testovací databázi o 30, 60 a 90 uživatelů, jevil průběh času lineárně, avšak byla-li by k dispozici databáze s větším počtem uživatelů, projevil by se tak na testovaném HW silný

exponenciální růst křivky, což by způsobilo prudký nárůst doby pro zpracování nového uživatele. Čas by tak stoupal k saturační hranici, která by pro real-time provoz systému byla neúnosná. Z teoretických grafů 3 a 4 můžeme odečíst jednotlivé doby, a to zhruba 4 minuty pro ukládání a necelých 6 min pro přihlášení uživatele do systému. Při takto početné databázi by se muselo poohlížet na použití vhodnějšího HW při realizaci sestavy a to tak, aby byl exponenciální charakter časové křivky zanedbatelný, viz teoretické odhady grafů 3 a 4.


6.2.2 *Test spolehlivosti*

Podle výše popsané teorie se spolehlivost biometrických systémů hodnotí dle uvedených výstupů a z toho vypočtených měr. Nejdůležitější faktory jsou však míra chybného přijetí (FAR) a míra chybného zamítnutí (FRR). Podle nichž se i dají dle teorie zvolit vhodně podmínky pro přijetí uživatele do systému. Jestliže se tyto chyby rovnají, jsou podmínky pro přijetí zvoleny správně, viz graf 1 v teoretických kapitolách. Jelikož ale v průběhu práce byly zvoleny dvě podmínky pro přijetí osoby do systému, nelze sestavit graf podobný tomu v teoretické části. Proto byl zvolen postup zhodnocení FAR vs. FRR odlišně, avšak se stejnou vypovídající hodnotou.

Graf 6 uvedený níže vypovídá o chování systému v závislosti na plnění jednotlivých podmínek během přihlašování osoby do systému. Pravděpodobnost chybného zamítnutí osoby činí 15,56%. Z této míry pravděpodobnosti pak osoba musí pokus opakovat, jelikož systém zamezí vstupu osoby kvůli nepřekročení prahu ve 2,2% případů, díky nedosáhnutí odstupu maximálních shod korelace v 8,9% pokusů a při nesplnění obou těchto podmínek zároveň ve 4,4% neúspěšných případech.



Graf 6 Míra chybného přijetí FRR



Graf 7 Koeficient vyrovnání chyb EER

Jak bylo uvedeno, míry FAR a FRR by měly být ideálně shodné, aby bylo dosaženo vhodně zvolených přijímacích podmínek. Toto tvrzení je však pouze teoretické, téměř ideálního stavu se tedy dosahuje pouze velmi zřídka. Jelikož je koeficient FAR míra bezpečnosti a koeficient FRR míra komfortnosti, systém byl nastaven tak, aby byl spíše bezpečnější na úkor komfortu, což lze vyčíst z grafu 7. Tyto podmínky pro přijetí byly ponechány z toho důvodu, že chyba FAR je mnohem závažnější než chyba FRR. Tento stav v praxi znamená, že daná osoba přihlášení do systému radši zopakuje, než aby se na její profil přihlásil někdo jiný. Dále lze z grafu 7 tvrdit, že systém je omylný v jednom z deseti případů a daná osoba musí pokus o přihlášení opakovat méně jak jednou ze šesti případů.

6.3 Sumarizace výsledků a doporučené rady pro další zpracování

Jednotlivé doby trvání nejsou pro uživatele až tak dlouhé, dá se tedy tento systém označit jako real-time fungující v přítomném čase. Uživatel je informován o výsledku v přijatelném časovém okamžiku. V případě opakování pořízeného snímku z důvodu špatné detekce duhovky nebo při chybném zamítnutí přihlášení by byl uživatel jistě ochoten proces opakovat.

Spolehlivost systému je přes nízké korelační koeficienty postačující pro účely předložené práce a její další plánovaný rozvoj. Pro nasazení systému do ostrého provozu je však nutno zvýšit spolehlivost systému a snížit jeho výkonovou náročnost, co se týká jednotlivých časových intervalů viz. předchozí podkapitoly.

Předložená práce je vhodná jako dobrý základ pro spolehlivý a použitelný biometrický systém užívaný v praxi. Pro případnou další práci na tomto projektu by bylo vhodné zapracovat na:

- Podrobnější databázi s menší datovou robustností
 - Databáze je pro použité účely dostačující avšak má za následky delší časové prodlevy při jednotlivých akcích uživatele. Do databáze by bylo vhodné také při použití v praxi vložit další doplňující informace o uživateli. Popřípadě propojit databázi se školním informačním systémem EDISON, čímž by se teoreticky mohla zvýšit rychlost celého přihlašovacího procesu, jelikož práce s databázovými servery je obecně samozřejmě rychlejší než v uvedeném případě.
- Otestování dalších možností způsobu extrakce příznaků
 - Což by mohlo mít za následek zvýšení korelačních koeficientů v porovnávací fázi a přispělo by tak ke zvýšení spolehlivosti navrženého systému.
- Optimalizaci používaného HW
 - Na jednotlivé časové prodlevy při zpracování snímku má velký vliv HW sestava používaná pro tuto práci. Bylo by tedy vhodné, vzhledem ke komfortnosti uživatele, při realizaci kompletního systému přihlížet na tento fakt.
- Obstatat přímou komunikací se snímacím zařízením duhovky
 - Navržený systém pouze zpracovává předem pořízené snímky, čímž tak simulují ostrý provoz. Pro další zvýšení spolehlivosti by také bylo vhodné uživatele informovat o jeho případné špatné poloze vůči snímacímu zařízení – implementace „trackovacího“ algoritmu oka v obraze s kruhovým terčem zachycujícím duhovku.

7 ZÁVĚR

Předložená diplomová práce pojednává o možných metodách využívaných při analýze a zpracování oční duhovky za účelem autentizace a identifikace uživatele. Metody zde uvedené ve skrze vycházejí z prací pana Daugmana, který nastínil tuto metodu biometrické identifikace již na konci 80. let 20. století. V následujících letech vznikaly další metody, jejichž základ se ale nadále nemění a obsahuje stejnou kostru jako používá samotný pan Daugman. Tyto metody se pak liší jen posledními kroky zpracování, čímž jsou určeny pro konkrétní případy užití.

Obecně je tento typ biometrického systému finančně nákladný a proto je využíván zatím jen zřídka. V České republice se doposud nenachází žádná firma, která by se tímto oborem biometrické identifikace zabývala na rozdíl od zahraničí, kde je situace o poznání lepší.

V rámci diplomové práce jsem splnil jednotlivé body zadání ve smyslu, sepsání podrobných rešerší jednotlivých metod, následně metod zabývajících se oční duhovkou, kterými jsem se inspiroval. V dalších krocích jsem tyto poznatky využil pro návrh a vhodnou implementaci algoritmu zpracovávající strukturu oční duhovky a dále navrhl další možné kroky pro doladění a uvedení celého systému do ostrého provozu.

Navržený systém není dokonalý a pro jeho nasazení do provozu se musí poupravit. Dosažené výsledky však mohou sloužit jako vhodný základ pro začátek dalšího výzkumu a jeho využití v praxi v oblasti identifikace osob ať už v implementaci pro nabíjecí stojany elektromobilů vyvíjené Vysokou školou Báňskou, nebo v jiných veřejně přístupných místech. Osobně věřím, že tento obor má svoji budoucnost v dnešní stále rychleji se vyvíjející společnosti a bude se stejným tempem rozvíjet i nadále.

Seznam použité literatury

- [1] RAK, Roman, MATYÁŠ, Václav, ŘÍHA, Zdeněk. *Biometrie a identita člověka*. Grada Publishing a.s. 2008. 664 s. ISBN 9788024723655
- [2] ŠČUREK, Radomír. *Biometrické metody identifikace osob v bezpečnostní praxi*. Ostrava: VŠB-TU Ostrava, 2008. 58 s. *Studijní text*
- [3] NÚDZIKOVÁ, Pavla. *Elektromobilita I: Identifikace uživatele*. Ostrava: VŠB-TU Ostrava 2014. 179 s. *Studijní text*
- [4] MA. Li, WANG, Yunhong, TAN, Tieniu. *Iris Recognition Using Circular Symmetric Filters*. 16th IEEE International Conference : Pattern Recognition. 2002. ISSN 1051-4651
- [5] DAUGHMAN, John. *New methods in Iris Recognition*. IEEE Transaction on Systems, Man, and Cybernetics – Part II. 2007. ISSN 1083-4419
- [6] DAUGHMAN, John. *How Iris Recognition Works*. University of Cambridge. 2002. ISSN 1522-4880
- [7] MASEK, Libor. *Recognition of Human Iris Patterns for Biometric Identification*. The University of Western Australia. 2003. 56 s. *Diplomová práce*
- [8] ČÍHÁK, Radomír. *Anatomie 2*. 2. vyd. Praha: Grada Publishing, a.s. 2004. 692 s. ISBN 80-247-1132-X
- [9] DRAHANSKÝ, M., ORSÁG, F. a DOLEŽAL, M. *Biometrie*. Brno: Computer Press, a.s. 2011. ISBN 978-80-254-8979-6.
- [10] HAIDEKKER, M. A. *Advanced Biomedical Image Analysis*. A John Wiley & Sons, Inc., 2011. ISBN 978-0-470-62458-6
- [11] JAN, J. *Medical Image Processing Reconstruction and Restoration: Concepts and Methods*. CRC Press, 2005. ISBN 0-8247-5849-8
- [12] WILDES, R. P. *Iris recognition: An emerging biometric technology*. Proceedings of the IEEE 85(9): 1997 Dostupný z:
<http://www.ieeexplore.ieee.org/iel3/5/13673/00628669.pdf>

- [13] RITTER, N. J.; COOPER, J.R. *Locating the iris: A first step to registration and identification*. Proceedings of the 9th IASTED International Conference of Signal and Image Processing: 507{512, 2003.
- [14] DOŇAR, K.; ZAPLATÍLEK, K. *MATLAB tvorba uživatelských aplikací*. 1. Vyd. Praha: BEN – technická literatura, 2004. 215s. ISBN 80-7300-133-0.
- [15] LI, M.; TIENIU, T.; YUNHONG, W.; DEXIN, Z. *Iris Recognition by Characterizing Key Local Variations*. Proceedings of the IEEE Transactions on Image Processing 13(6): 739{750, 2004.
- [16] BOWYER, K.,W, HOLLINGSWORTH, K. a FLYNN, P., J. 2008. *Image understanding for iris biometrics: A survey*. *Computer Vision and Image Understanding* [online]. 5., vol. 110, no. 2, pp. 281–307 [cit. 2014-11-07]. ISSN 10773142.
- [17] DUDA, R.O. - HART,P.E. *Use of the Hough Transformation to detect Lines and Curves in Pixtures*. 1972, Graphics and Image Processing, Vol.15, pp.1-15. [cit. 2014-09-25].
- [18] WALEK, P., LAMOŠ, M. a JAN, J. *Analýza biomedicínských obrazů - Počítačová cvičení*. VUT Brno: Fakulta elektrotechniky a komunikačních technologií, 2013. ISBN 978-80-214-4792-9.
- [19] ZVÁROVÁ, J. *Základy statistiky pro biomedicínské obory*. 2., dopl. vyd. Praha: Karolinum, 2011, 219 s. ISBN 978-80-246-1931-6.
- [20] NIXON, M.S.- AGUADO,A.S. *Feature Extraction and Image Processing, second edition*. Amsterdam : Elsevier, 2008 [cit. 2013-11-16]. ISBN: 978-0-12372-538-7.
- [21] TOBIÁŠOVÁ, N. *Biometrie s využitím snímků duhovky*. VUT Brno: Fakulta elektrotechniky a komunikačních technologií, 2014.
- [22] MathWorks. *Documentation*. [online]. 6.10.2014 [cit. 2014-10-6]. Dostupné z: <http://www.mathworks.com/help/>

Seznam příloh

Příloha č.1: M-file programu: Nacteni.m, detekce.m, matching3.m

Příloha č.2: Figure GUI programu: Nacteni.fig

Příloha č.3: Soubor prázdné databáze: templates.mat; soubor plné databáze: templates90.mat

Příloha č.4: Datový nosič DVD-ROM s kompletními přílohami: testovací databáze CASIA
+ přílohy 1 až 4